

**SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN**

Pero Batinić

**IMPLEMENTACIJA VELIKIH VRSTA
PODATAKA U CRM**

DIPLOMSKI RAD

Varaždin, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Pero Batinić

Matični broj:44793/16-R

Studij: Ekonomika poduzetništva

IMPLEMENTACIJA VELIKIH VRSTA PODATAKA U CRM

DIPLOMSKI RAD

Mentor:

Izv.prof.dr.sc. Damir Dobrinić

Varaždin, 2018.

Pero Batinić

Izjava o izvornosti

Izjavljujem da je moj diplomski rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristio drugim izvorima osim onima koji su u njemu navedeni. Za izradu rada su korištene etički prikladne i prihvatljive metode i tehnike rada.

Autor potvrdio prihvaćanjem odredbi u sustavu FOI-radovi

Sažetak

Big Data i CRM su dva relativno nova pojma koji u posljednjih nekoliko godina ostvaruju veliki rast u svijetskom poslovanju. Svaki pojam za sebe apsolutno je utjecao na razvoj i promjene kako u marketingu tako i u svim funkcijama u poduzeću. Big Data se odnosi na način prikupljanja velikih količina podatka koji se kasnije pohranjuju, obrađuju i na pravilan način ekstrahiraju s ciljem postizanja pravih odluka u pravo vrijeme. CRM je s druge strane, složen sustav djelovanja poduzeća s ciljem da svoje akcije, proizvode ili usluge usmjeri na način postizanja prisnijih odnosa sa svojim kupcima i time podignu vrijednost svog poduzeća, prateći isključivo zahtjeve i potrebe kupaca. Međutim, bez obzira na to, ova dva područja su još nedovoljno istražena i zbog toga svrha ovog rada je prikazati jedan i drugi sustav posebno kao cjelinu u poslovanju, ali i njihovu kompatibilnost i mogućnost zajedničkog djelovanja u stvaranju boljeg i efikasnijeg poslovanja.

Ključne riječi: CRM, Kupci, Big Data, Big Data CRM, Rudarenje, Baza podataka, Marketing baza podataka

Sadržaj

1.Uvod	1
1.1. Predmet i cilj rada	1
1.2. Metodologija rada	1
1.3. Sadržaj rada	2
2.Pojam i značenje velikih količina podataka	3
2.1. Tipovi velikih podataka	6
2.1.1. <i>Strukturirani podaci</i>	6
2.1.2. <i>Nestrukturirani podaci</i>	8
2.2. Big Data vs Small Data	10
2.3. SMART model	11
2.4. Korištenje velikih podataka u praksi	17
3.Korištenje velikih podataka u marketingu	19
3.1. Marketing baza podataka	20
3.2. Big data i digitalni marketing	23
3.3. Big data i 4P	24
3.4. Načini korištenja velikih podataka	26
4.Strategija upravljanja zadovoljstvom kupaca	29
4.1. Istraživanje zadovoljstva	30
4.1.1. <i>Određivanje ciljeva istraživanja</i>	31
4.1.2. <i>Vrste prikupljanja podataka</i>	31
4.2. Analiza podataka o zadovoljstvu	32
4.2.1. <i>Obrada i analiziranje podataka</i>	33
4.3. Mjerenje zadovoljstva	34
4.4. CRM i zadovoljstvo kupaca	38
5.Upravljanje i organizacija CRM-a	40
5.1. Vrste CRM-a	42
5.1.1. <i>Strateški CRM</i>	42
5.1.2. <i>Operativni CRM</i>	44
5.1.3. <i>Analitički CRM</i>	46
5.2. Implementacija CRM-a	48
5.3. Prednosti i nedostaci CRM-a	52
6.Korištenje velikih podataka u CRM-u	55
6.1. Rudarenje podataka	56
6.2. Skladištenje podataka	58
6.3. Razvoj i upravljanje bazama podataka povezanim s kupcima	60
6.3.1. <i>Sigurnost baze podataka</i>	63

7. Anketa	64
8. Zaključak	76
Popis literature	78
Popis slika	84
Popis tablica	85
Popis grafikona	86

1.Uvod

Krajnji cilj svakom poduzeću danas bi trebalo biti postizanje što boljih odnosa sa svojim kupcima jer oni su ključan segment poslovanja bez kojeg poduzeće ne bi moglo postojati. Prije je to bilo puno teže, ali danas zbog napredne tehnologije podatke o kupcima je moguće prikupiti iz velikog broja različitih izvora. Upravo je to tema ovog diplomskog rada kojem je svrha pojasniti pojam velikih podataka te njihovo kompatibilno djelovanje zajedno sa CRM sustavom.

1.1. Predmet i cilj rada

Ova tema je značajna iz razloga što se radi o relativno novim pojmovima koji još nisu detaljno razrađeni. S toga, ovaj rad nastoji pružiti jasna objašnjenja na sve nepoznanice koje se vežu uz velike podatke i CRM. Motivacija za odabir teme je veliko zanimanje za CRM sustav kao poslovnu funkciju u poduzeću. Također ovo je aktualna tema koja se trenutno jako puno povlači po internetu, što uvijek donosi dodatnu euforiju nego kada se istražuje nešto što je već zastarjelo. Uz dodatak velikih podataka, jako je zanimljivo, ali u drugu ruku i zastrašujuće vidjeti na koje sve načine je moguće danas pratiti kupce i pristupiti njihovim osobnim podacima.

Ciljevi kojima se želi ostvariti svrha su definirati pojmove Big Data i CRM, utvrditi na koji način se big data primjenjuje u marketingu i u kojim područjima marketinga, zatim prikazati korištenje podataka kroz strategiju upravljanja zadovoljstvom kupaca, prikazati značenje CRM sustava u poduzeću, razjasniti korištenje velikih podataka u samom CRM-u te provesti istraživanje kako bi se uvidjelo kolika razina ova dva pojma je prisutna u hrvatskim poduzećima i koje koristi ostvaruju od njihova zajedničkog djelovanja.

1.2. Metodologija rada

Metode koje će se u radu primjenjivati su metoda analize, sinteze i komparativna metoda. Metoda analize i sinteze primjenit će prilikom sekundarnog pretraživanja literature pri čemu će se odvajati bitne od manje bitnih stvari i nakon toga će se te izdvojene stvari objediniti i zajedno priložiti u pregledu rada. Poslije sekundarnog pretraživanja literature, provest će se primarno istraživanje hrvatskih poduzeća putem ankete. Nakon primarnog istraživanja primjenit će se komparativna metoda za analiziranje i uspoređivanje odgovora ispitanih poduzeća.

1.3. Sadržaj rada

Rad je podijeljen u osam poglavlja, a to su: uvod, pojam i značenje velikih količina podataka, korištenje velikih podataka u marketingu, strategija upravljanja zadovoljstvom kupaca, upravljanje i organizacija CRM-a, korištenje velikih podataka u CRM-u, anketa i zaključak.

U uvodu se objašnjava svrha i motivacija za pisanje rada, navode se ciljevi i opisuju metode koje će se koristiti te se daje kratki pregled sadržaja po poglavljima. Naziv drugog poglavlja je pojam i značenje velikih količina podataka. U drugom poglavlju definirat će se pojam velikih podataka, prikazati osnovni tipovi podataka, usporediti veliki i mali podaci, objasniti SMART model podataka koji pomaže poduzećima upravljati pametnim podacima te na kraju navesti nekoliko primjera korištenja velikih podataka u praksi.

Korištenje velikih podataka u marketingu naslov je trećeg poglavlja u koje će se definirat pojmovi marketing i marketing baza podataka, pojasniti povezanost velikih podataka sa digitalnim marketingom i marketinškim miksom te na kraju navesti nekoliko načina korištenja velikih podataka od strane stručnjaka za različite svrhe u marketingu. Naziv četvrtog poglavlja je strategija upravljanja zadovoljstvom kupaca. U četvrtom poglavlju definirat će se pojam zadovoljstvo kupaca, objasniti istraživanje, analiziranje i mjerenje zadovoljstva te prikazati poveznica između zadovoljstva i CRM sustava.

Peto poglavlje je upravljanje i organizacija CRM-a u kojem će se definirat CRM kao poslovna funkcija u poduzeću, objasniti njegove vrste, prikazati koraci implementacije te navesti njegovi nedostaci i koristi za poslovanje samog poduzeća. Naziv šestog poglavlja je korištenje velikih podataka u CRM-u. U šestom poglavlju će se prikazati poveznica između velikih podataka i CRM sustava preko rudarenja i skladištenja podataka te pojasniti razvoj baze podataka i njezina sigurnost.

U sedmom poglavlju navodi se cilj provođenja istraživanja te se prikazuju analizirani odgovori anketiranih poduzeća. U konačnom poglavlju naziva zaključak, ukratko će biti izneseni svi rezultati rada i potvrđene postavljene pretpostavke.

2.Pojam i značenje velikih količina podataka

U današnje vrijeme raznih mogućnosti i moderne tehnologije, razvio se relativno novi pojam koji je uzburkao i utjecao na daljnje djelovanje različitih djelatnosti, posebice marketinga. Taj pojam je "Big Data" odnosno veliki podaci. To je jedan od pojmova o kojem svi govore, a nitko nije skroz uvjeren da zna točno o čemu se radi. Može se reći da je to nova paradigma koju karakterizira veliki rast podatka kroz različite izvore.

Na temelju toga, Strong (2015.) ističe kako su elementi velikih podataka izlučeni kroz opažanja, izračunavanja, eksperimente, zapisivanje raznovrsnih aktivnosti i slično. Krajnji odabir podataka ovisi od osobe do osobe iz razloga što svaka osoba najbolje zna koje informacije su joj najpotrebnije.

Kod velikih podataka važno je obratiti pozornost na proizvodnju podataka. Čovjek svojim djelovanjem na internetu ostavlja različite tragove oko kojih poduzeća generiraju i fokusiraju svoje ideje. Upravo zbog prisutnosti na internetu, Arthur (2013.) navodi kako se podaci akumuliraju kroz neko vrijeme, preko uređaja i različitih web značajki i tako postaju veliki podaci. Upravo zbog te mogućnosti praćenja kupaca, velike količine podataka prikupljaju se isključivo s ciljem shvaćanja želja i potreba kupaca.

Kocijan (2014.) navodi kako veliki podaci ili „big data“ označavaju novu eru u kojoj će se svijet lakše kvantificirati i razumijeti. Na početku ove ere može se reći da je razvijena nova disciplina. Iako se ona na prvi pogleda može činiti redundantnom, tu ideju treba ponovo razmotriti uzevši upozorenje da je cjelovitost velikih podataka kao discipline puno veća nego zbroj njegovih dijelova.


Rubinstein (2013.) govori kako se „big data“ odnosi na nekoliko načina u kojima različite organizacije, uključujući vlade i poslovne subjekte, kombiniraju različite digitalne setove podataka i nakon toga koriste statistiku i druge metode rudarenja podataka. Sve to odvija se s ciljem otkrivanja i dobivanja ključnih informacija koje znatno poboljšavaju poslovanje, ali uz sva ta poboljšanja, javlja se veliki problem privatnosti kako osoba tako i poduzeća.

Prilikom pretraživanja na internetu ili čitanjem razne literature od mnogo različitih autora, može se naići na različite definicije velikih podataka odnosno „big data“. Pa tako Arthur (2013.) smatra kako je „big data“ kolekcija podataka od tradicionalnih i digitalnih izvora koji predstavljaju izvor za neprekidajuće istraživanje i analizu. Bez obzira na životu u digitalnom svijetu i prikupljanje digitalnih informacija, tradicionalni načini prikupljanja i izvori podataka nikako se ne smiju zaboraviti jer i oni čine važan dio poslovanja.

Moorthy, Lahiri, Biswas, Sanyal, Ranjan, Nanath, Ghosh (2015.) govore o tome kako je „big data“ kao izraz u velikoj mjeri amofran i nejasan. Upravo iz razloga što mnogo različitih ljudi gleda na taj fenomen iz nekoliko perspektiva te je zbog toga teško odrediti njezinu točnu definiciju.

Prema Strong (2015.) „big data“ nema točnu definiciju nego je to istaknuto kroz nekoliko značajki. Te značajke odnose se na veličinu podataka, brzinu prikupljanja, različitost i fleksibilnost. Veličinu karakterizira volumen odnosno ukupna količina podataka koje je moguće prikupiti, brzina se odnosi na mogućnost prikupljanja podataka u datom trenutku i na temelju njih donošenje brzih odluka. Različitost znači da postoji veliki broj različitih izvora i vrsta podataka koji se mogu prikupiti što nam pomaže u boljem razumijevanju različitog ponašanja kupaca. Fleksibilnost kao značajka velikih podataka odnosi se na to da je u svakom trenutku moguće proširiti područje promatranja i prikupljanja potrebnih podataka.

Kroz svaku definiciju velikih podataka provlače se i njezini temeljni čimbenici pa tako, Berman (2013.) spominje tri sastavna čimbenika velikih podataka, a to su volumen, brzina i raznovrsnost. Volumen se odnosi na velike količine podataka koji se prikupljaju, raznolikost na to da se podaci mogu pojaviti u nekoliko različitih oblika dok se brzina naposljetku odnosi na brzinu promjene sadržaja i brzinu kretanja podataka.



Slika 1. Koncept 3V (Izvor : Šebalj, Živković, 2016.)

U svijetu velikih podataka nije važno kolika količina podataka se može prikupiti, već kako pravilno pristupiti toj skupini podataka i iz nje izvući one podatke koji su najvažniji za poslovanje. Pravilna analiza podataka može utjecati na poboljšanje poslovanja i stjecanje

novih kupaca. Samim time, Marr (2015.) navodi kako nije količina podataka ta koja stvara razliku nego naša sposobnost analiziranja bespriječnih i kompleksnih setova podataka. Naprednost današnje informacijske tehnologije uz pomoć interneta omogućila je bržu analizu podataka odnosno drugim riječima iz velikih količina podataka jasnije se izvlače podaci sa najvećom i najznačajnijom vrijednošću za poslovanje.

Mayer-Schonberger i Cukier (2013.) govore kako je „big data“ zapravo ideja u kojoj volumen informacija je narastao toliko puno da količina podataka koja se prikupljala nije više mogla pohranjivati zbog nedostatka prostora što je naposljetku potaknulo ljude na razvoj novih alata za obradu, analiziranje i pohranjivanje podataka.

Šebalj, Živković, Hodak (kao što citira Knapp) definiraju kako je „big data“ alat, procesi i procedure koje omogućuju organizacijama da stvore, manipuliraju i vode vrlo velike setove i skladišne jedinice. Također navode kako ujedinjavanje i analiza velikih podataka znatno povećava efektivnost organizacija i omogućuje menadžmentu da donosi bolje poslovne odluke.

Miglani (2016.) definira „big data“ kao velike komade strukturiranih i nestrukturiranih podataka. Volumen pohrane takvih podataka je jako ogroman, stoga postaje važno da analitičari pažljivo kopaju cijelu stvar čineći ga smislenim i korisnim za donošenje odluka.

„Big data“ je naziv koji objašnjava veliki volumen podataka bili oni strukturirani ili nestrukturirani koji poplavljuju poduzeća na dnevnoj bazi. No, međutim nije važna količina podataka nego što organizacije rade sa tim podaci je mnogo važnije. Ona može biti analizirana iz različitih uvida koji vode boljim strateškim poslovnim odlukama. (SAS Institute Inc, bez dat.)

„Big data“ je pojam koji se primjenjuje na skupove podataka čija je veličina ili vrsta izvan sposobnosti tradicionalnih relacijskih baza podataka za upravljanje i obradu podataka s niskom latencijom. Ima jednu od sljedećih karakteristika, a to su : visoki volumen, velika brzina i velika razlika. Veliki podaci dolaze od različitih senzora, uređaja, video/audio, mreža, aplikacija, društvenih mreža i slično. Veliki broj od njih se generira u stvarnom vremenu i u velikoj mjeri. (IBM, bez dat.)

Hurwitz, Nugent, Halper, Kaufman (2013.) definiraju „big data“ kao kombinaciju starih i novih tehnologija koje pomažu poduzećima da stvore djelotvoran uvid. Također „big data“ je sposobnost vođenja velikog obujma neskladnih podataka, pravom brzinom i u pravom vremenskom okviru, da se omogući pravovremena analiza i reakcija.

Mnoge velike korporacije poput Walmart-a ili Amazona imaju mogućnosti i tehnologije za kombiniranje velikih podataka o svojim kupcima. Veliki podaci time mijenjaju prirodu poslovanja bilo kojeg odjela unutar poduzeća. Na temelju te pretpostavke, Marr (2015.)

objašnjava kako također uz pomoć mobitela i tekstualnih obrazaca preko socijalno-medijalne analitike, poduzeća mogu klasificirati svoje kupce u različite kategorije. Praćenje kupaca putem različitih uređaja omogućuje poduzećima preciznije mjerenje zadovoljstva i fokusiranje na ponude koje su pravi odraz kupčevih želja i potreba.

Trend prikupljanja velike količine podataka te njihovo korištenje u različite svrhe zaista mijenja način poslovanja kakav je nekada postojao. Preciznije prikupljanje ključnih informacija pomaže poduzećima u razvoju preciznijih kampanja, predviđanju budućih aktivnosti i naposljetku samih budućih potreba kupaca. Čak i izvan poslovanja, „big data“ projekti već pomažu promijeniti svijet na više načina, kao što su to: (Marr, bez dat., str.2)

- **Poboljšanje zdravstva** – analiziranje velikih podataka u zdravstvu omogućuje ljudima da pomoću detaljnih istraživačkih metoda otkrivaju bolesti i formule za razvoj novih lijekova
- **Predviđanje i reagiranje na prirodne i ljudske katastrofe** – analiziranjem velikih podataka mogu se predvidjeti različite prirodne katastrofe i time pravovremeno djelovati te pomoći ljudima koji će biti zahvaćeni katastrofom
- **Sprječavanje kriminala** – pravilnom obradom podataka policija može točnije raspoređivati resurse prilikom različitih akcija

2.1. Tipovi velikih podataka

Razvoj tehnologije i interneta pridonio je nastanku različitih vrsta podataka. Kako postoje brojni izvori podataka, tako postoje i broji oblici podataka u kojima se oni pojavljuju odnosno prikupljaju. Tipovi velikih podataka povezani su sa menadžmentom podataka jer je za lakše korištenje važno njihovo pravilno razvrstavanje. Važno je razlikovati podatke generirane od strane ljudi i podatke generirane od strane različitih uređaja i aplikacija, zbog toga što su ljudski podaci često manje pouzdani i nečisti.

Prema tome, Hurwitz i sur. (2013.) navode dva ključna faktora koja su zaslužna za podjelu podataka na dvije osnovne vrste. Prvi je to da se podaci generiraju sa različitih uređaja, pametnih telefona i tableta, a drugi faktor je taj da velike količine podataka koje su se prikupljale, nisu se mogle iskorištavati na koristan i upotrebljiv način. Upravo zbog toga postoje dvije osnovne vrste podataka, a to su strukturirani i nestrukturirani.

2.1.1. Strukturirani podaci

Šebalj i Živković (2016) navode kako je to najčešće baza podataka u kojoj su podaci lako

čitljivi i lako se pretražuju. Strukturirani podaci su prikazani jednostavnim oblikom te u njihovu analizu se ne pridodaje previše vremena jer su oni već posloženi na pravilan način. Tu spadaju podaci o kupcima i dobavljačima, ulazni i izlazni računi i slično. Arthur (2013.) pak daje drugačiju definiciju strukturiranih podataka, koja glasi da se to odnosi na različite formate i vrste podataka te da se mogu izvesti iz interakcija između ljudi i strojeva kao što su naprimjer društvene mreže ili različite web aplikacije.

Hurwitz i sur. (2013.) nadovezuju se na to i govore kako su to podaci koji su definirani određenim formatom. To su naprimjer brojevi, datumi, grupe riječi i brojeva kao kupčeva adresa i slično. Ova vrsta podataka čini vrlo mali dio od ukupno svih podataka koji se prikupljaju iz različitih izvora. Zbog svog već definiranog oblika pohranjuju se na prikladno mjesto gdje će se dalje koristiti. Nove tehnologije pogodovale su novim izvorima strukturiranih podataka. Izvori ovih podataka podijeljenje su u dvije razine. Prva razina je ona u kojoj su podaci generirani putem računala, dok je druga razina ona u kojoj se podaci generiraju od strane čovjeka u interakciji sa računalom.

U strojno generirane strukturne podatke spadaju sljedeći: (Hurwitz i sur.,2013.,str 26,27)

- **Senzorski podaci** – tu spadaju različite tehnologije poput RFID-a, GPS-a, medicinski uređaji i slično. Takva vrsta tehnologije omogućuje poduzećima razne prednosti. Danas su poduzeća u mogućnost pratiti količinu zaliha na skladištu, lokaciju pošiljaka i slično. Osim toga GPS tehnologija im pomaže u razumijevanju kupčevih aktivnosti.
- **Podaci web zapisa** – korištenje weba omogućuje prikupljanje dosta različitih podataka, samo je važno tko prikuplja te podatke i na koji način se oni nastoje iskoristiti.
- **Prodajni podaci** – kada blagajnik provuče bar kod proizvoda koji smo kupili, svi podaci povezani s proizvodom se generiraju. Ako uz kupnju kupac još priloži i karticu lojalnosti, svi podaci povezani uz nju pohranjuju se u bazi te njihovom detaljnom analizom omogućuje se praćenje kupčevih potreba.
- **Financijski podaci** – mnogi financijski sustavi sada rade na temelju unaprijed definiranih automatiziranih procesa. Trgovanje dionica na burzi vrlo je dobar primjer strukturiranih podataka iz razloga što podaci određenih dionica su jasno navedeni. Prilikom kupnje ili prodaje jasno je vidljiv znak poduzeća kojem dionica pripada, vrijednost odnosno cijena dionice, element rasta ili pada i slično.

U podatke generirane od strane čovjeka spadaju sljedeći: (Hurwitz i sur.,2013.,str.27)

- **Ulazni podaci** – ulazni podaci su podaci koje čovjek samostalno unosi u računalu. U te podatke spadaju općeniti podaci koji se koriste prilikom izrade svakog kupčevog

profila. Takvi podaci mogu biti vrlo korisni u predviđanju ponašanja i djelovanja kupaca.

- **Klikovni podaci** – prilikom posjeta osobe određenoj web stranici svaki klik ostaje zabilježen. Na temelju podataka o klikovima, poduzeća mogu bolje odrediti želje svojih kupaca, ali i generirati preciznije ponude prema svakom pojedincu zasebno.
- **Podaci povezani sa igrima** – svaki pokret koji se napravi u igri može biti snimljen. Ovi podaci mogu poslužiti za razumijevanje kako se krajnji korisnici kreću kroz igrači portfolio.

2.1.2. Nestrukturirani podaci

Ova vrsta podataka predstavlja veliki izazov za poduzeća iz razloga kojeg navode Šebalj i Živković (2016), a to je da ovakvu vrstu podataka je vrlo teško svrstati u pravilan format. To mogu biti slike, grafički podaci, video sadržaji, web stranice, tekstualne datoteke, mailovi, različite objave i slično.

Marr (2015.) govori kako se nestrukturirani podaci analiziraju iz različitih ljudskih aktivnosti kao što su razgovor, slike i sve ostale aktivnosti koje čovjek obavlja korištenjem interneta. Sve što se pretražuje na pregledniku definitivno ostaje zabilježeno. Kada se priča o web stranicama, one bilježe koliko ljudi je kliknulo i posjetilo stranicu, odakle korisnici dolaze, koliko dugo su se zadržali i slično. Dok Arthur (2013.) smatra kako su nestrukturirani oni podaci koji dolaze od informacija koje nisu organizirane i lako se intepretiraju od strane tradicionalnih baza podataka. Postovi na društvenim mrežama su odličan primjer nestrukturiranih podataka.

Hurwitz i sur. (2013.) govore kako se ovdje radi o podacima koji nisu popraćeni pravilnim formatom, te su oni velika većina podataka koja se prikuplja, jer mali dio pripada strukturiranim podacima kao što je ranije navedeno. Nestrukturirani podaci su zapravo većina podataka s kojima se ljudi svakodnevno susreću. Do nedavno, tehnologija nije pružala neku podršku radeći s njima, osim što je omogućila njihovu pohranu i kasnije se sve to ručno analiziralo.

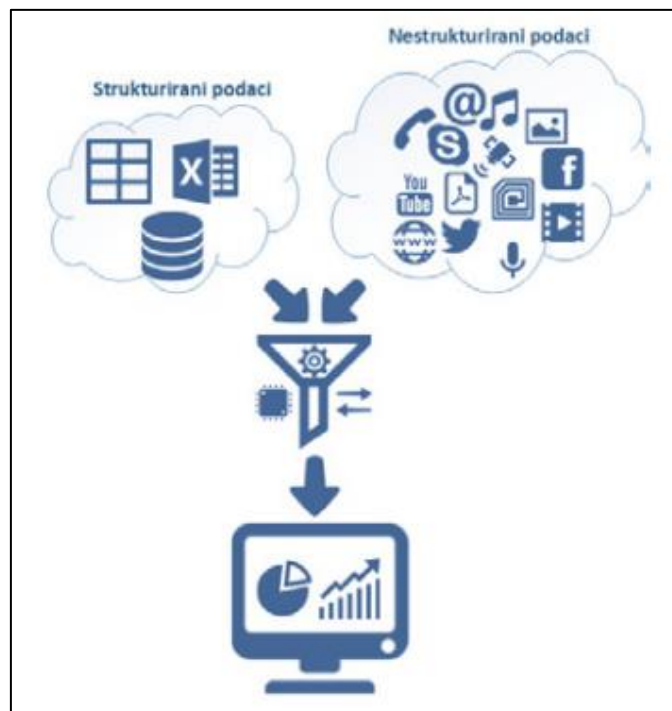
Nestrukturirani podaci se nalaze svugdje. Zapravo većina pojedinaca i organizacija vode svoje živote oko nestrukturiranih podataka. Također kao i kod strukturiranih podaka, nestrukturiranih podaci su strojno i ljudski generirani. Primjeri strojno generiranih podataka: (Hurwitz i sur.,2013.,str.29,30)

- **Satelitske slike** – to uključuje vremenske podatke i slike satelitskog nadzora.
- **Znanstveni podaci** – uključuje seizmičke slike, atmosferske podatke i slično.

- **Fotografije i video** – zaštita, nadzor, promet i slično.
- **Podaci radara**

Primjeri nestrukturiranih podataka koji su ljudski generirani: (Hurwitz i sur.,2013.,str.30)

- **Unutarnje poruke u poduzeću** – podaci zapravo predstavljaju veliki postotak tekstualnih informacija u svijetu.
- **Podaci o društvenim mrežama** – podaci su generirani na društvenim mrežama poput YouTube-a, Facebook-a i slično.
- **Mobilni podaci,sadržaj web stranica itd.**



Slika 2:Tipovi podataka (Izvor: Šebalj, Živković, 2016)

Hurwitz i sur. (2013.) navode kako još uvijek mnogi ljudi smatraju da je pojam nestrukturiranih podataka varljiv, upravo zbog toga što svaki dokument može sadržavati vlastitu specifičnu strukuru ili biti oblikovan na način koji ga je određeni software stvorio. Ali međutim, ono što je interno dokumentu je uistinu nestrukturirano. Slučajevi uporabe nestrukturiranih podataka su u porastu tj. brzo se šire. Rješenje problema je u detaljnoj analizi pomoću koje se prolazi kroz tekst te iz njega izvlače najvrijednijih podaci koji se zatim koriste u različite svrhe ovisno o potrebi.

2.2. Big Data vs Small Data

Small Data je skup malih podataka koji mogu utjecati na donošenje odluka u sadašnjosti. Uz to, Miglani (2016.) navodi kako ta pomoć u donošenju odluka nema za cilj utjecaj na poslovanje u velikoj mjeri, već na kraći vremenski period. Sastoji se od određenih i specifičnih skupova podataka koji se mogu koristiti za analizu trenutačnih situacija. Specifični skupovi podataka koji su izvedeni nakon kopanja velikih podataka također se mogu nazvati malim podacima. Kada se pojave problemi unutar poduzeća koje je potrebno brzo riješiti, tada je najbolje koristiti brze metode analize malih podataka, a ne metode za analizu velikih podataka.

Na to se nadovezuje, Baeza-Yates (2013.) koji smatra kako se mali podaci najbolje mogu sažeti kao svi podaci koji su dovoljno mali da ih ljudi razumiju, tumače i koriste kako bi poduzeli određene radnje. u najjednostavnijem obliku, jedan mali sitni dio koji pokreće da ili ne odluku smatra se malim podacima.

Osnovne razlike između velikih i malih podataka kroz deset čimbenika: (Berman.,2013,str.13,14)

1. **Ciljevi** – mali podaci su dizajnirani da trenutno daju odgovore na određeno pitanje te služe rješavanju točno postavljenog cilja. Dok su veliki podaci dizajnirani sa ciljem u mislima. Taj cilj je fleksibilan, a pitanja koja se postavljaju uz taj cilj su promjenjiva i raznovrsna.
2. **Lokacija** – mali podaci se tipično nalaze na jednom mjestu dok su se veliki podaci proširili izvan mjesta pohranjivanja kao što su internet te različiti serveri.
3. **Struktura i sadržaj podataka** – mali podaci obično su visoko strukturirani i najčešće se odnose na jedan objekt te su pravilnog formata dok veliki podaci su nestrukturirani pravilno i mogu se odnositi na nekoliko objekata istovremeno. Osim toga veliki podaci zahtijevaju detaljniju analizu.
4. **Priprema podataka** – male podatke osoba najčešće prikuplja sam te ih ona samostalno i analizira u svoje privatne svrhe, dok velike podatke prikuplja nekoliko osoba iz razloga što je ta radnja kompliciranija jer podaci mogu dolaziti iz različitih izvora. Veliki podaci se ne koriste u osobne svrhe, u velikom broju slučajeva prikupljaju se za različita poduzeća.
5. **Dugovječnost** – kod malih podataka, kada završi projekt podaci se čuvaju u ograničenom vremenu i zatim se odbace. Projekti s velikim podacima uobičajeno sadrže podatke koji moraju biti pohranjeni vječno. Velike podatke prikupljene za

različite projekte nije poželjno bacati jer uvijek se može pojaviti novi projekt u kojem se ti podaci mogu iskoristiti.

6. **Mjerenja** – mali podaci se mjere uz pomoću jednostavnijih metoda i to u jednom mjernom lancu te se prikazuju jednim jednostavnim skupom rješenja. Veliki podaci sadrže podatke različitih formata zbog dolaska iz različitih izvora što znatno otežava mjerenje i sami mjerni lanac. Potvrđivanje vrijednosti velikih podataka jedan je od najtežih zadataka za upravitelja podataka.
7. **Obnovljivost** – projekti kod malih podataka su obično ponovljivi iz razloga što je male količine podataka vrlo lako duplicirati odnosno ako su iz njih izvedeni kvalitetni zaključci. Dupliciranje velikih podataka u projektu je teško izvedivo. U većini slučajeva, svatko se može nadati da će loši podaci biti na vrijeme pronađeni i označeni kao takvi.
8. **Financijska ulaganja** - kod malih podataka troškovi su vrlo mali što ne predstavlja problem kod oporavka u slučaju pojave određene nezgode ili kvara. Međutim, projekti sa velikim podacima mogu biti poprilično skupi, a pogreške i kvarovi mogu dovesti do bankrota i masovnog gubitka svih podataka i resursa poduzeća.
9. **Introspekcija** – kod malih podataka, individualne točke podataka su identificirane redom i stupcem unutar proračunske tablice ili baze podataka. Kada je to poznato mogu se uvijek pronaći i odrediti podatci koji su sadržani unutra. Kada je izvor velikih podataka izuzetno dobro dizajniran, sadržaj i organizacija resursa mogu biti neprobojni, čak i za upravitelja podataka.
10. **Analiza** – prednost malih podataka je u tome što ih se može analizirati zajedno, dok za analizu velikih podataka postoji proces u kojem se kroz svaki korak obavlja određena aktivnost s ciljem dobivanja konačnog rezultata.

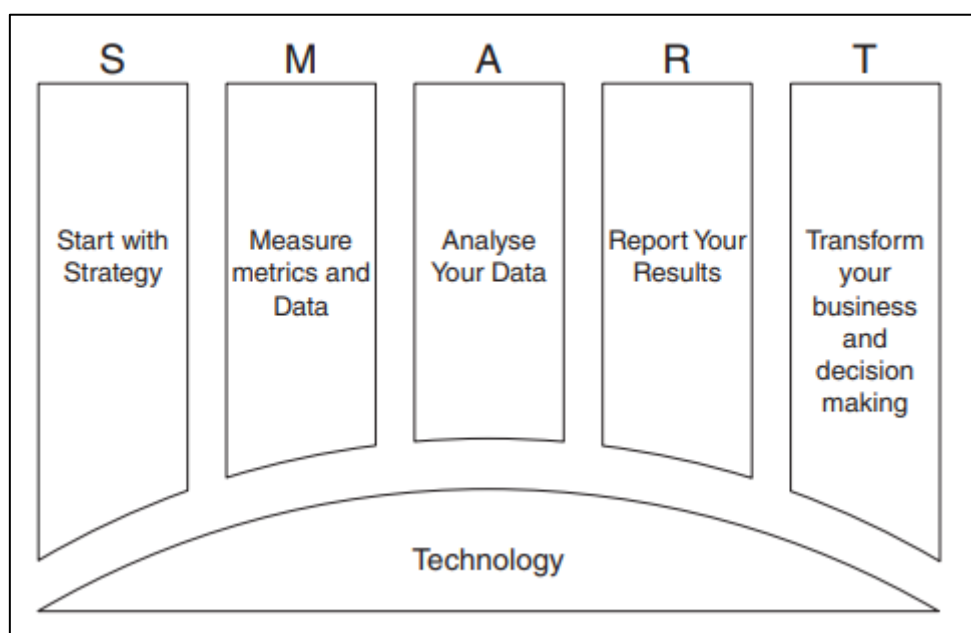
Kao zaključak, Miglani (2016.) naglašava kako se usporedbom ove dvije vrste podataka može jasno vidjeti da su veliki podaci u većoj mjeri kompliciraniji i teže ih je analizirati. Dok je s druge strane male podatke puno lakše razumijeti i analizirati. Zajednička stvar malim i velikim podacima je ta da imaju mogućnost utjecati na poslovanje poduzeća i njihovo donošenje odluka.

2.3. SMART model

Veliki podaci mogu revolucionirati poslovanje, ali samo ako se fokusiraju na pametne podatke, odnosno one koji su najvažniji za poduzeće. Upravo zbog toga Bernard Marr razvio

je Smart model kako bi se pomoglo poduzećima da stvore pametno poslovanje i iskoriste ogromnu moć velikih podataka sukladno poduzeću i budžetu.

Lee-Dennis (2016.) definira pametne podatke kao napredniji set velikih podataka, odnosno to je sposobnost izvlačenja najpouzdanijih podataka iz velike sume prikupljenih podataka na bilo kojoj razini poslovanja. Temelji se na izvlačenju uvida iz najrelevantnijih podataka koji su algoritamski analizirani.



Slika 3. SMART model (Izvor: Marr, 2015)

Marr (2015.) smatra da rješavanje bilo kakvog problema mora kretati od pravilno određene strategije. Važno je da poduzeće zna gdje želi biti, koji su mu glavni ciljevi u ostvarivanju te krajnje pozicije. Potrebno je istaknuti da postavljeni ciljevi moraju biti temeljeni na ranije postavljenoj strategiji. Sve ranije navedeno pomaže u određivanju podataka koje treba prikupiti kako bi se riješili problemi koji koče poslovanje. Nakon toga usmjerava se na način pristupanja podacima. Kada se ustanovi koje podatke koristiti, potrebno je primijeniti analitičke metode kako bi iz tih podataka izvukli najvažnije uvide koji su nam potrebni.

U nastavku Marr (2015.) ističe kako sve ovo ne bi bilo moguće bez pomoći tehnologije. Tehnologija ubrzava proces prikupljanja podataka, olakšava njihovo analiziranje i razumijevanje konačne poante koja se koristi u daljnjem provođenju aktivnosti. Kada se podacima pristupa sa više pažnje i fokusiranosti tek tada je moguće krenuti ostvarivati poboljšanja u poslovanju.

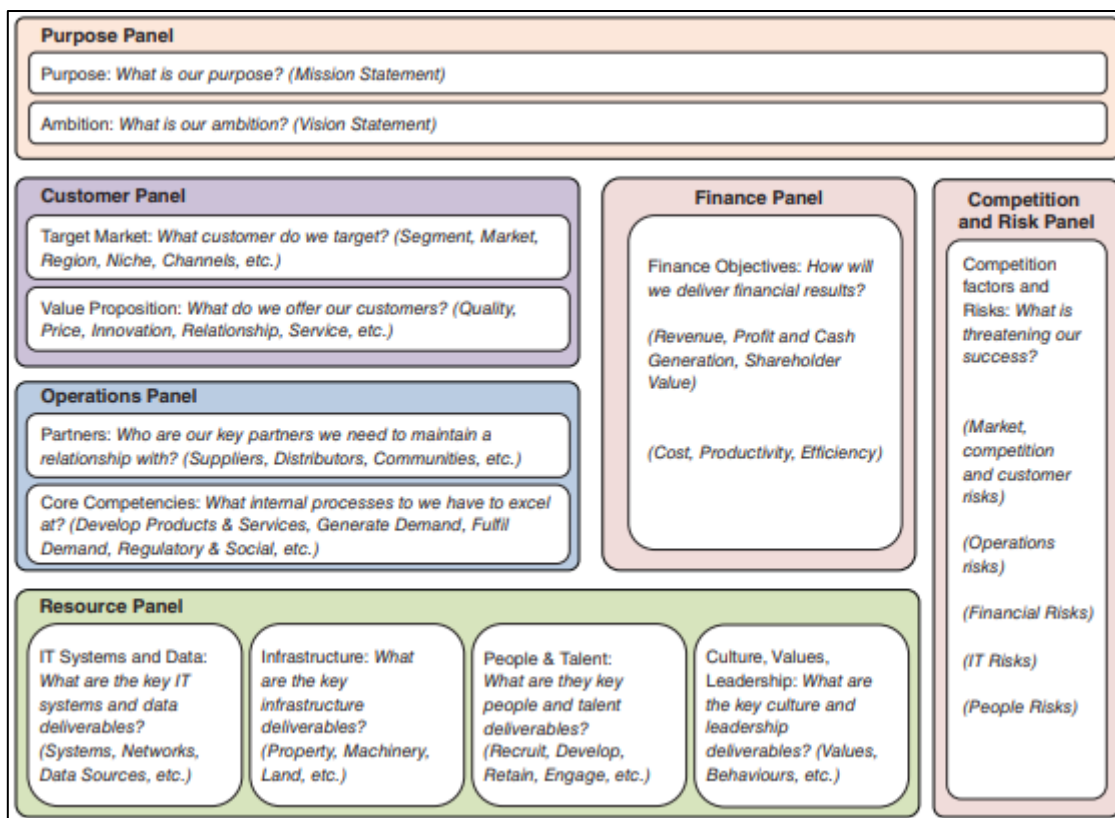
1.Započni sa strategijom (S)

Marr (2015.) u ovom dijelu govori kako svako pametno poslovanje kreće od strategije. Stvar je u tome što velikanima poput Walmart-a i Amazona svaki mali dio podataka može biti jako

vrijedan do određene mjere. To je sve zbog toga što takva poduzeća imaju jako puno iskustva, novca i tehnologije kojima mogu razviti dovoljne kapacitete skladištenja i rudariti onda te podatke kako bi stvorili neki određeni uvid. To je moguće smo u slučaju velikana zbog toga što 99,9 posto poduzeća nema potrebno vrijeme, novac, iskustvo i tehnologiju za analiziranje podataka.

Ako tvrtka ima pristup velikoj količini podataka koji se mogu rudariti i analizirati, onda je definitivno vrijedno potrošiti 10% analitičkih napora za otkrivanje podataka. Otkrivanje podataka je gledanje podataka iz drugog smjera. Kada se krene sa strategijom, radi se na tome što se mora znati i prikupljaju se podaci kako bi se pronašli potrebni odgovori. U otkrivanju podataka, podaci se promatraju bez postavljanja pitanja ili dnevnog reda kako bi se uvidjelo što ti podaci govore o stanju u poduzeću. U budućnosti bi ova vrsta otkrivanja podataka mogla znatno utjecati na poslovanje ili čak kompletno promijeniti model funkcioniranja poduzeća kroz sve funkcije. (Marr, 2015)

U velikoj većini slučajeva podaci imaju vijek trajanja. To je veoma važno cijeniti iz razloga što veliki podaci znaju otežavati život poduzećima jer se stvara osjećaj nedostatka vremena za obradu svih podataka, osjećaj manjka prostora za pohranjivanje i općenito osjećaj pretrpanosti velikom količinom podataka. Ali zapravo to nije istina zbog toga što podaci o kupcima mnogih poduzeća, koji su stariji od 5 godina zapravo nemaju neku vrijednost. Razlog zašto su velika poduzeća tako uspješna je taj što oni mogu pristupiti velikoj bazi sadašnjih kupaca i pomoću toga mogu profilirati i targetirati svakog klijenta zasebno i time poboljšati performasu. Poželjno je da poduzeća odbacuju podatke koji su znatno prešli granicu od 5 godina starosti. Upravo je to poanta prvog koraka, u kojem se razvija strategija kojom se utvrđuju najvažniji i najpotrebniji podaci. (Marr, 2015)



Slika 4: SMART strategijski predložak (Izvor: Marr,2015)

Cilj ovog predloška je pomoći poduzećima steći uvid u to kako posjedovanje pravih informacija može biti konkurentna prednost. Poduzeća jasno moraju definirati informacijske potrebe koje će kasnije uskladiti sa strategijom poslovanja. Vrlo je važno fokusirati se i koristiti najpotrebnije informacije kako bi se izbjegla zatrpanost nepotrebnim stvarima. Podaci mogu stvoriti veliku vrijednost za poduzeće, ali samo ako ih se koristi na pravilan način. (Marr ,2015.)

SMART strateški predložak sastoji se od šest panela, a to su : (Marr,2015)

- **Panela namjene** – pomaže definirati misiju i viziju poduzeća te odrediti koja je svrha i ambicija prikupljanja podataka.
- **Korisnička panela** – pomaže u određivanju ciljanog tržišta i ciljane vrijednosti prema kupcima. Također preko ove panele moguće je odrediti razinu poznavanja vlastitih kupaca.
- **Financijska panela** – dizajnirana je iz potrebe poznavanja financijskih implikacija strategije. Kako stvara novac, da li je to siguran poslovni model i slično.
- **Operacijska panela** – omogućuje točno određivanje unutarnjih procesa koji će pomoći u održavanju odnosa s kupcima. Također razmišlja se o poslovnim partnerima koji će pridonijeti ostvarenju tog cilja.

- **Panela resursa** – omogućuje razmatranje resursa koji su potrebni kako bi se pravilno dostavila strategija. Sastoji se od četiri komponente, a to su: IT sustavi i podaci, infrastruktura, ljudi i talent te vrijednosti i vodstva.
- **Panela konkurencije i rizika** – procjenjuje kolika konkurencija i rizik se mogu naći na putu u provođenju zamišljene strategije.

2. Mjeri metrike i podatke (M)

Marr (2015.) u ovom dijelu navodi različite vrste podataka. Govori o strukturiranim, nestrukturiranim i polustrukturiranim podacima, internim i eksternim podacima, podacima o aktivnosti, podaci koji se prikupljaju na temelju razgovora, video podacima, senzorskim podacima i slično. Također spominje anatomiju „big data“ koja se sastoji od volumena, brzine i raznolikosti. Nakon pokretanja strategije i identificiranja SMART pitanja vezanih uz kupce, financije, operacije, resurse i rizik potrebno je odrediti metrike i podatke kojima se mora pristupiti kako bi se odgovorilo i na postavljena pitanja.

Poznavajući sve o vrstama podataka, postavlja se logička hijerarhija koju je potrebno slijediti kod identificiranja metrika. Ta hijerarhija izgleda slijedeće: prvo se pretražuju interni strukturirani podaci, zatim interni polustrukturirani podaci, zatim interni nestrukturirani. Nakon internih, pretražuju se prvo eksterne strukturirane metrike i na samom kraju pretražuju se eksterne nestrukturirane metrike. Marr (2015.)

Iznad internih i eksternih, strukturiranih i nestrukturiranih, postoji sedam glavnih načina prikupljanja podataka: (Marr,2015,str.86-88)

- **Kreirani podaci** – kreiraju se iz točno određenog razloga, najčešće iz mehanizma „pitanja-odgovori,“. Primjer toga su programi lojalnosti. Naprimjer, nakon korisnikove prijave u sustav on time svojevoljno daje određene podatke o sebi.
- **Isprovocirani podaci** – provocirani su jer ne bi postojali ako se ne pozovu ljudi da izraze svoje poglede. Primjer takvih podataka bi bilo kada se pita kupca da ocjeni određene proizvode i usluge.
- **Transakcijski podaci** – generiraju se svaki puta kada kupac kupi nešto. To je moguće kod klasične i online kupnje i time se pruža snažan uvid u ono što je kupljeno, gdje je kupljeno i kada je kupljeno.
- **Sastavljeni podaci** – nazivaju se sastavljeni jer se kombiniraju iz različitih ogromnih baza podataka. Specijalizirane tvrke sastavljaju velike količine podataka iz različitih izvora te često koriste ime i adresu klijenta kao zajednički indikator.
- **Eksperimentalni podaci** – Oni uključuju izradu eksperimenata u kojima različiti setovi kupaca zaprimaju različite marketinške tretmane.

- **Prikupljeni ili zarobljeni podaci** – zarobljeni iz razloga što se odnose na informacije koje se pasivno prikupljaju o ponašanju pojedinca.
- **Korisničko generirani podaci** – podaci koje korisnici ili tvrtke svjesno sami kreiraju.

3. Analiziraj podatke(A)

Podaci sami nisu baš od neke pomoći ako ne postoje prave metode analiziranja, kojima se ti podaci pretvaraju u vrijednost koja naposljetku pomože u oblikovanju strategije i donošenju odluka.

Postoje tri uobičajene vrste analitika: (Marr,2015)

1. **Tekstualna** – postupak izdvajanja informacija i uvida iz velikih količina teksta. Pristup ogromnim skupovima tekstualnih podataka i poboljšana tehnička sposobnost omogućili su rudarenje tekstualnim uzorcima i traženje onog što je najkorisnije za poslovanje. Sastoji se od zadataka koji uključuju kategorizaciju teksta, grupiranje teksta, ekstrakciju koncepta, analizu sentimenta i sažetak dokumenta.
2. **Govorna** – poput teksta, audio snimke i razgovori se također mogu analizirati. Danas je moguće koristiti govornu analitiku da analiziramo emocionalni sadržaj razgovora. Naprimjer, call centri preko intonacije i visine glasa mogu mjeriti koji klijent postaje ljut ili frustriran. Analiziranje i kategoriziranjem snimljenih razgovora između tvrtki i njihovih klijenata, danas je moguće otkriti strateške značajke odnosno informacije o proizvodima, procesima, područja unaprijeđenja poslovanja i odnosa s klijentima. Takve informacije daju donositeljima odluka jako dobar uvid o tome što klijent misli o poduzeću i to im pomaže da regiraju na brzi i pravilan način.
3. **Slika/video analitika** – Ima veliki utjecaj na kupčevo ponašanje, sigurnost, osobnu privatnost, borbu protiv terorizma i slično. Tu još spadaju prepoznavanje lica, analitika ponašanja, svijest o situaciji i slično. Uz to spominju se vrijednost, transparentnost i problem privatnosti jer kada se radi o analitici uvijek je važno biti iskren i transparentan o potrebi podatka koji se traže i o namjeri njihova korištenja.

4.Izvjestiti o rezultatima (R)

Marr (2015.) navodi kako samo primjena analitike nije dovoljna. Važno je izvjestiti o uvidima koji su ekstrahirani iz podataka na način razumljiv ljudima. Poslovni lideri se još uvijek bore sa svim podacima koji dolaze za njihov stol te je vrlo važno jasno izvjesiti te rezultate. Nakon što se analiziraju podaci koji se trebaju uzeti u obzir kako bi se donjele bolje strateške odluke, važno je te podatke vizualizirati i prikazati ih na pravilan način sukladno potrebama koji zahtijevaju takvu vizualizaciju. Ta vizualizacija je moguća u obliku grafikona, dijagrama, teksta, karata, ponašanja i slično.

5.Transformiranje poslovanja i donošenja odluka (T)

Metrika, podaci i analiza mijenjaju svijet uključujući i onaj poslovni. Koliko puno i koliko daleko je netko spreman ići ovisi o rukovodećima koji upravljaju poduzećima. No, već postoje mogućnosti za: (Marr, 2015.,str.199)

- bolje razumijevanje i targetiranje kupaca,
- poboljšanje i optimiziranje poslovnih procesa,
- poboljšanje ljudskog zdravlja,
- povećanje sigurnosti i smanje prijevare,
- upravljanje poslom i ljudskom performansom,
- poboljšanje gradova i ostale infrastrukture.

2.4.Korištenje velikih podataka u praksi

Postoji deset područja primjene velikih podataka u praksi te u tim područjima podaci se mogu staviti u gotovo svaku svrhu. Tih deset područja su: (Marr, bez dat.)

1. **Poboljšanje razumijevanja kupaca** – ovo je jedan od najvećih i najopćenitijih područja korištenja velikih podataka danas. Ovdje se podaci koriste kako bi se bolje razumjelo ponašanje i preferencije kupaca. Mnoge tvrtke žele proširiti svoje tradicionalne skupove podataka s podacima sa društvenih mreža, preglednika kao i tekstualnom analizom i slično kako bi dobili potpuniju sliku svojih klijenta. Veliki je cilj, u mnogim slučajevima, stvaranje prediktivnih modela.
2. **Razumijevanje i optimizacija procesa** – trgovci su u mogućnosti optimizirati svoje zalihe na temelju podataka generiranih iz različitih izvora. Također jedan od procesa koji u velikoj mjeri koristi analizu velikih podataka je opskrbni lanac i definiranje rute isporuke. Geografsko pozicioniranje i senzori za radiofrekvencijske signale koriste se za praćenje robe ili vozila.
3. **Osobna kvantifikacije i optimizacija izvedbe** – veliki podaci nisu samo za tvrtke i vlade, već i za sve pojedince. Sada se koristi mogu ostvariti od podataka koji su generirani od strane različitih nosivih uređaja kao što su pametni satovi ili narukvice.
4. **Poboljšanje zdravstva i javnog zdravlja** – računalna snaga analize velikih podataka omogućuje ljudima danas da dekodiraju cijeli DNK lanac u nekoliko minuta, također omogućava pronalaženje novih lijekova, bolje razumijevanje i predviđanje obrazaca različitih bolesti.
5. **Poboljšanje sportskih izvedbi** – većina elitnih sportova je prihvatila analizu velikih podataka. Naprimjer, tu je IBM SlamTracker za teniske turnire koji mjeri brzinu udarca

loptice, zatim koristi se video analiza koja prati izvedbu svakog igrača u nogometnoj ili bejzbol ligi i slično.

6. **Poboljšanje znanosti i istraživanja** – znanost i israživanje trenutno se znantno transformira novim mogućnostima koje donose veliki podaci. Naprimjer, CERN, labaratorij nuklearne fizike sa najvećim i najmoćnijim akceleratorom čestica na svijestu. Svakodnevni eksperimenti koji se tamo događaju generiraju ogromne količine podataka.
7. **Optimiziranje strojeva i uređaja** – veliki podaci pomažu uređajima i strojevima da postanu pametnijima. Naprimjer, veliki podaci se koriste kako bi pokrenuli automobile koje ne voze ljudi, automobili su opremljeni kamerama, GPS-om i slično. Auto može voziti sam bez ikakve ljudske intervencije i time generirati veliki broj podataka.
8. **Poboljšanje sigurnosti i provođenje zakona** – veliki podaci se koriste za prikazivanje terorističkih urota, zatim spriječavanje cyber napada, predviđanje kriminalističkih aktivnosti i slično.
9. **Poboljšanje i optimizacija gradova i država** - veliki podaci se koriste kako bi poboljšali mnoge aspekte gradova i zemalja. Naprimjer, pomaže gradovima optimizirati tokove prometa na temelju informacija o prometu u stvarnom vremenu.
10. **Financijsko trgovanje** – korištenje velikih algoritama podataka za donošenje odluka o trgovanju.

3.Korištenje velikih podataka u marketingu

Prije samih objašnjenja korištenja velikih podataka u marketingu. Važno je podsjetiti se što je to marketing. Marketing je vrlo kreativan proces stvaranja marke, komunikacije s kupcima, načina distribuiranja proizvoda, promocija i slično. On nije samo prodaja niti će ikad biti. Osim u prodaji marketing pomaže i u privlačenju kupaca, partnera, općenito u stvaranju boljih veza kako unutar tako i izvan poduzeća. Također to je i način predstavljanja poduzeća, proizvoda i usluga kupcima, te mu iz tog razloga moramo posvetiti malo više pažnje.

To mogu potvrditi, Kotler i Armstrong (2017.) koji definiraju marketing kao proces kojim poduzeća privlače kupce, izgrađuju s njima odnos i stvaraju vrijednost. Marketing ima dvostruki cilj, a tu je da privuče nove kupce obećavajući im vrijednost i da zadrži te nastavi rast sa trenutnim kupcima dajući im također vrijednost i zadovoljstvo.

Marketing je aktivnost, skup institucija i procesa za stvaranje, komuniciranje, isporuku i razmjenu ponuda koje imaju vrijednost za klijente, kupce, partnere i društvo u cijelini. (American Marketing Association, bez dat.)

Martin (2014.) navodi kako prema gore navedenoj definiciji se lako može vidjeti veza između velikih podataka i marketinga. Informacije mogu donijeti uvid u proizvod koji omogućuje stvaranje proizvoda kojeg ljudi žele. Pomaže shvatiti kako učinkovito komunicirati vrijednost proizvoda. Strategiju distribucije moguće je optimizirati radi dostavljanja proizvoda potrošaču i pravilnog određivanja odgovarajuće stope razmjene što će rezultirati zdravom dobiti. Ukratko, što više informacija se posjeduje time se bolje marketinške odluke donose.

Spencer (2014.) govori o tome kako prodajni predstavnici u marketingu promatraju velike podatke raširenih očiju. Upravo zbog toga što veliki podaci mogu potencijalno opisati ciljne klijente s velikom točnošću i detaljima. Dok su stare marketinške aktivnosti bile ograničene na praćenje povrata od kampanje izravne pošte i broj preplatnika kataloga, moderni djelatnici marketinga danas mogu imati podatke o navikama ljudi tijekom vježbanja, ponašanju u digitalnom okruženju, vremenu provedenom na različitim web mjestima, povijesti kupnje, osobne postavke na društvenim mrežama i mnoge druge stvari koje je nemoguće ni zamisliti.



Slika 5. Razlika starog i modernog kupca (Izvor: Spancer,2014)

Na slici su prikazane dvije vrste kupaca. Sa lijeve strane prikazan je stari kupac kakvog su prodajni i marketinški djelatnici nekada poznavali dok je sa desne strane prikazan moderan kupac. Drugim riječima, danas uz pomoć velikih podataka puno je lakše pronaći dodatne informacije o kupcima ili klijentima, odnosno veliki podaci stvaraju definiranije kupce u realnom i dinamičnom vremenu.

3.1. Marketing baza podataka

Kako bi se razumijelo što je to marketing baza podataka, važno je prvo znati što su to baze podataka. Pa tako, Banasiewicz (2013.) definira baze podataka kao organiziranu kolekciju podataka. Iako mnogi povezuju bazu podataka sa modernim računalnim aplikacijama, taj pojam je postojao i mnogo prije pojave modernog računalnog računanja. Tu se još spominje i poslovna baza podataka koja je definirana kao elektronički pohranjena kolekcija podataka i koja kao takva zahtjeva svoj vlastiti menadžerski sistem te specijalizirane alate za upite i analizu.

Tapp, Whitten i Housden (2014.) definiraju marketinšku bazu podataka kao elektroničku verziju uredskog kabineta koji sadrži evidenciju o kupcima. Naprimjer, zamisli se kako je svaki kupca zapisan u obliku kartice na kojoj se nalaze njegovi opći podaci, podaci o transakciji, povijest njegove kupnje i slično. Kartice se mogu držati u različitim datotekama te mogu biti preusmjerene u druge datoteke kako bi se kupce lakše odabralo po različitim karakteristikama. Točnije, smatra se kako je to popis klijenata i planova koji omogućuju stratešku analizu, pojedinačne odabire za komunikaciju i službu za korisnike. Svi važni podaci se organiziraju oko kupaca.

Armstrong, Kotler, Harker i Brennan (2009.) govore kako je baza podataka o kupcima, zbirka sveobuhvatnih podataka o pojedinačnim kupcima te uključuje geografske, demografske, psihografske podatke i podatke o ponašanju svakog kupca.

Četiri vrste podataka koje bi marketinški predstavnici željeli u svojim bazama podataka : (Tapp i suradnici,2014,str.34)

1. **Primarni podaci** – tu spadaju imena i adrese kupaca, pojedinosti o proizvodima i uslugama koje nude organizacije, pojedinosti o cijeni, kampanjama i različiti kanali distribucije.
2. **Sekundarni podaci** – ovdje spadaju podaci koji se koriste za kvalificiranje primarnih podataka, kao što su demografija, informacije vezane za način života, zemljopisni profili i razine penetracija na tržištu.
3. **Podaci o izvedbi** – na temelju njih snima se kako klijenti reagiraju, što su kupili, koliko su potrošili i na koje su kampanje reagirali.
4. **Vanjski podaci** – pokrivaju sve što se iznajmljuje ili kupuje od različitih agencija koje mogu poboljšati bazu podataka.

Blattberg, Kim i Neslin (2008.) definiraju marketing baza podataka kao sposobnost upravljanja ili vođenja računalno relacijske baze podataka, sveobuhvatnih i ažuriranih podataka o kupcima, upita, perspektiva i slično u realnom vremenu. Cilj svega toga je identificiranje osjetljivijih kupaca, stvaranje visokokvalitetnog i dugogodišnjeg odnosa preko prediktivnih modela kojima se šalju željene poruke pravim ljudima i sve to u skladu sa zadovoljavanjem klijenata, povećanjem stope odgovora, snižavanjem troškova narudžbe i povećanjem profita.

Schmid i Weber (1998.) navode kako je marketing baza podataka proces izdvajanja svih relevantnih informacija iz kupčeve kupnje te korištenje istih za buduće marketinške programe i kontakt s kupcima. Osnovne informacije uključuju ono što kupci kupuju, koliko kupuju i koliko često kupuju. Pravi marketing baza podataka omogućuje postizanje krajnjeg cilja, a to je uspostavljanje odnosa jedan na jedan sa kupcima ili klijentima.

Važno je napomenuti tri stvari koje su vezane uz marketing baza podataka. Prvo, njegova osnova je korištenje baze podataka o kupcima. Kupac može biti trenutni ili potencijalni. Za potencijalne kupce firme mogu dobiti demografske, psihografske pa čak i podatke o povijesti kupnje, ali ne iste dubine kao i za sadašnje kupce. Drugo, marketing baza podataka je ključan za marketinšku produktivnost i to preko pravilnog targetiranja. Marketing baza podataka prepoznaje koja polovica marketinških napora tvrtke je izgubljena. To čini preko toga što vidi koji kupci reagiraju na marketing, a koji ne. Treće, marketing baza podataka se odnosi na upravljanje kupcima. Kupci moraju biti stečeni, zadržani i razvijeni. Stjecanje kupca znači dobiti pojedinca koji trenutno ne poslije s tvrtkom da krene poslovati s njom. Također je bitno i zadržavanje kupaca tj. osigurati njegovo poslovanje sa tvrtkom što je duže moguće. (Blattberg i sur.,2013.)

Danas se postavljaju dva važna pitanja, a to su: zašto je marketing baza podataka postao toliko važan i zašto je ta industrija postala toliko velika? Blattberg i suradnici (2013.) daju odgovore na ta pitanja i govore o tome kako postoji šest glavnih razloga porasta ove industrije, a to su informacijska tehnologija, rast interneta, niža produktivnost masovnog marketinga, marketinška odgovornost, povećan interes u odnose s klijentima i uspostavljanje konkurentske prednosti. Što se tiče važnosti, ističu tri glavna faktora, a to su:

- **Povećanje produktivnosti marketinga** – vrlo je važno identificirati postupke koji se ne isplate, kako bi poduzeće tada moglo svoje napore okrenuti prema onima koji su produktivni i od kojih imaju koristi. Baza podataka upravo pomaže u tome, jer ona identificiranjem otkriva prema kojim kupcima će određeni postupak ili kampanja biti najuspješnija i na temelju toga poduzeće može točnije targetirati kupce. Što znači da je marketing baza podataka temelj segmentacije i targetiranja.
- **Omogućavanje razvoja odnosa prema klijentima** – temelji se na dvije strategije. Prva je ta da zadržavanje kupaca je jeftinije nego stjecanje novih, a druga je ta koja govori da je povećanje zadržavanja kupaca znatno vrijednije od povećanja stjecanja novih. Važno je naglasiti kako je zadržavanje kupaca atraktivan način za izgradnju bolje performanse poduzeća.
- **Stvaranje održive konkurentske prednosti** – marketing baza podataka iskorištava kupčevu datoteku sa informacijama koja je u vlasništvu određenog poduzeća. Poduzeće tako preko tih informacija može bolje služiti svojim kupcima. Pomoću njih poduzeće može identificirati pravilnu uslugu koju treba ponuditi, dati preporuku proizvoda ili učinkovitije prilagoditi promocije. Takvo poznavanje informacija daje poduzeću konkurentsku prednost u odnosu na konkurenciju jer bi ona trebala previše platiti za dobivanje takvih informacija.

Martin (2014) navodi nekoliko prednosti korištenja velikih podataka u marketingu, a to su:

- Stvaranje točnijeg profila ciljanih kupaca
- Predviđanje reakcija potrošača na marketinške poruke i ponude proizvoda
- Personaliziranje marketinških poruka i ponuda proizvoda
- Optimiziranje proizvodne i distributivne strategije
- Stvaranje i korištenje preciznijih mjera procjene
- Savršen digitalni marketing i strategije temeljene na kampanjama
- Zadržati više kupaca i dobiti uvid u proizvod

3.2. Big data i digitalni marketing

Digitalni marketing je mogućnost pristupanja kupcu u bilo koje vrijeme bez obzira na njegovu lokaciju preko različitih uređaja. Također jedna od njegovih prednosti je mogućnost preciznog mjerenja i analiza postignutih rezultata. Zahvaljujući digitalnom marketingu u svakom trenutku moguće je dobiti preciznu informaciju koju treba povezati s ciljem postizanja postavljenih poslovnih ciljeva.

Kotler i Armstrong (2017) definiraju digitalni marketing kao korištenje digitalnih alata poput web stranica, društvenih mreža, mobilnih aplikacija, email-a, videa i slično, pomoću koji se angažira kupca bilo gdje i u bilo koje vrijeme preko kupčevih digitalnih uređaja.

Shukla (bez dat.) govori kako danas mnogo različitih organizacija koristi podatke iz različitih izvora kako bi poboljšalo svoje digitalne marketinške kampanje. Uz pomoć velikih podataka kampanje su dokazano učinkovitije u odnosu na stare metode oglašavanja. Uzimajući u obzir nagađanja, marketinški stručnjaci mogu otkriti promjenjive trendove i tako ih koristiti za više ciljanih kampanja. Količina podataka koja se dobije je nadmoćna, što zahtjeva veće ulaganje u složenije baze i alate za analizu kako bi se osigurala sve najpotrebnije informacije. Razotkrivanje spoznaja rezultira boljom sposobnošću pronalaženja mogućnosti i angažmana kupaca.

Alati za vizualizaciju podataka mogu znatno poboljšati učinkovitost kampanja. S porastom konkurencije, zahvaljujući digitalnom dobu i internetu, danas marketinški stručnjaci pronalaze načine za brzo razumijevanje i tumačenje podataka. Odluke se donose na temelju kolektivnog razumijevanja podatkovnih točaka. U stvarnom vremenu uvid u potrošače može pomoći pri stjecanju više klijenata i smanjenju gubitaka. Analiza potrošačkih podataka pomoću alata za analize znači da su marketinški timovi spremni bolje odgovoriti na promjene potrošačevih zahtjeva. Također upotreba podatka o prošlim događajima može pomoći u planiranju za budućnost. Marketinški stručnjaci mogu analizirati ono što se radilo u prošlosti i na temelju toga donositi bolje buduće odluke. Potaknuti uvidima potrošača mogu planirati buduće kampanje i aktivnosti sa većim stupnjem sigurnosti. (Shukla, bez dat.)

Martin (2014.) navodi kako je internet glavni i vodeći izvor velikih podataka. Sve od analitike web stranica do društvenih mreža, klikovnih oglasa i slično može se lako grupirati, analizirati i tumačiti. Uz internet razvili su se i neki ostali izvori kao što su oglašavanje banerima, marketing pomoću tražilice, marketing sadržaja, priča o robnoj marki, društvene mreže, mobilno reklamiranje i slično.

Na to se nadovezuje Shukla (bez dat.) sa svojih pet glavnih izvora velikih podataka za povećanje rezultata kampanja, a to su:

- **Web rudarenje** – podaci se prikupljaju rudarenjem, odnosno koriste se automatizirani alati za otkrivanje i izdvajanje podataka iz web dokumenata i poslužitelja.
- **Društvene mreže** – omogućuju marketinškim stručnjacima da prikupe velike količine podataka, od osobnih preferencija do spominjanja robne marke i slično.
- **Podaci pretraživanja** – to su podaci prikupljeni pomoću različitih alata za praćenje informacija o pretraživanju i utvrđivanju namjere i ponašanja korisnika.
- **Praćenje transakcija** – svaka transakcija pruža korisne podatke o korisnicima, bilo financijske, logističke ili druge povezane podatke. Organizacije mogu koristiti takve transakcije kako bi imali uvid u aktivnosti ciljane publike.
- **Velike skupine ljudi** – proces prikupljanja javne inteligencije. Proučavanje velikih zajednica ljudi koji su povezanim istim interesima.

3.3. Big data i 4P

Marketinški miks ili skraćeno 4P je pojam sa kojim je upoznata velika većina ljudi. Za 4P može se reći kako je to osnovni marketinški pojam koji se sastoji od četiri ključna elementa, a to su cijena, proizvod, mjesto i promocija. Vrlo je važno da se ta četiri elementa ujednače jer ako samo jedan od njih izgubi ravnotežu, postoji mala šansa da se bilo kakva aktivnost obavi na kvalitetan način. Povezivanje marketinškog miksa s velikim podacima pogodovalo je poboljšanjima u njegovu provođenju.

Na temelju toga, Martin (2014.) navodi kako korištenje velikih podataka ima implikacije za svaki aspekt marketinga. Marketing se često opisuje u smisli 4P, a to su promocija, proizvod, mjesto i cijena. Neki marketinški stručnjaci često dodaju i peti dio, a to je pakiranje ili ambalaža. Upravo zbog toga što veliki podaci mogu pomoći u razumijevanju preferencija potrošača kako bi na temelju toga oblikovali vrstu ambalaže koja bi privukla potrošače i lakše dovela do kupnje.

1.Cijena

Uključivanjem različitih podataka u stvarnom vremenu, kao što su podaci o dobavljačima i inventaru, modeli potrošačke vrijednosti kupnje, financijske prognoze i slično, tvrtke pomoću toga mogu primjenjivati dinamičko određivanje cijena što im omogućuje da ponude različite cijene, u različito vrijeme, na različitim mjestima i to različitim kupcima kako bi optimizirale prihode. Dobar primjer za to su hoteli, koji na određeni dan mogu ponuditi standardnu tarifu na svojoj web stranici. Zatim naprimjer, kada se hotel krene puniti, hotelski menadžment

može podići cijenu sobe jer soba je potražnja i kratka ponuda. Također tvrtka može varirati cijene na temelju potrošača ili njihovih karakteristika. (Martin,2014)

2.Proizvod

Jedan od najčešćih koristi vezanih uz proizvod je dobivanje uvida o njemu. Tvrtke danas mogu jeftinije i jednostavnije provoditi kvalitativno i kvantitativno online istraživanje tržišta. Također poduzeća mogu pratiti web i društvene mreže u kojima se spominje njihova marka proizvoda od strane potrošača, zatim mogu pregledavati analitiku vlastite digitalne imovine i interpretirati različite informacije kako bi otkrili idealna proširenja proizvoda. (Martin,2014)

3.Mjesto

Marketinški stručnjaci mogu koristiti velike podatke kako bi odredili optimalne kanale za postavljanje svojih proizvoda. U skladu s tim, mogu postaviti optimalan opskrbeni lanac. Najbolji primjer ove situacije su novine. Mnoge novine, suočene su s godinama smanjivanja prihoda od oglašavanja i pretplate, upravo zbog toga okrenule su se internetu. Koju opciju utvrditi i postaviti online može se odrediti pomoću pažljive analize velikih podataka. (Martin,2014)

4.Promocija

Veliki podaci mogu pomoći potrošačima da odrede ciljeve za kupnju proizvoda. Marketinški stručnjaci mogu lako testirati poruke. U rukama sposobne marketinške istraživačke tvrtke, veliki podaci mogu se koristiti za testiranje i predviđanje reakcije potrošača na različite poruke. Naprimjer, tvrtka koja je poslala skupinu mailova prema 250.000 potrošača može koristiti marketinške podatke za stvaranje psihografskog profila prosječnog potrošača. Na temelju otvaranja ili klikovnog postupka tvrtke mogu predividjeti potencijalne klijente i mogu ih pomaknuti dalje u prodajni tok. (Martin,2014)

Mnogi autori smatraju kako su veliki podaci otključali veliki potencijal za poslovanje, ali također stvorili i neku novu vrstu marketinga. Pristup velikom broju strukturiranih i nestrukturiranih podataka omogućuje da stručnjaci preko marketinškog modeliranja i raznih drugih analitičkih alata iskorištavaju velike podatke za poboljšanje marketinških napora i djelovanja. Upravo zbog utjecaja velikih podataka na marketing razvijen je novi 4P, koji će kako tvrdi Bowden (2014.) pomoći ljudima da shvate zašto trebaju brinuti o velikim podacima u svojim marketinškim programima.

Bowden (2014.) opisuje taj novi marketinški miks kroz četiri ključna područja, a to su:

1.Performans

Pojava velikih podataka omogućila je stručnjacima prikupljanje korisnih podataka na temelju kojih mogu donositi pravilne odluke u stvarnom vremenu. Također u mogućnosti su koristiti

detaljnije metode i analize čime postižu veću razinu svojih performansi u poslovanju. Osim toga veliki podaci utječu i na bolje reagiranje prema kupčevim potrebama.

2. Personalizacija i preferencije

Ovaj dio odnosi se na izgradnju bolje personaliziranih odnosa s kupcima. Veliki podaci su glavni resurs za povezivanje s kupcima preko različitih tehnologija i mobilnog marketinga. Drugim riječim, veliki podaci omogućuju intimnije odnose između poduzeća i njegovih kupaca, a veza je personalizirana ponuda prilagođena potrebama i željama kupaca.

3. Predviđanja

Predviđanje se odnosi na ubrzanje procesa prikupljanja, obrade i analize podataka radi boljeg poboljšanja poslovanja. Veliki podaci i novi analitičke metode omogućile su pojavu automatiziranijeg načina prikupljanja i obrade podataka te time pomogle poduzećima da predvide potrebe svojih kupaca.

4. Privatnost

Najbolji način rješavanja problema privatnosti je taj da stručnjaci jednostavno osmisle uvjete i odredbe koje će kupcima otkriti kako se zapravo koriste njihovi osobni podaci. To naposljetku, daje bolju kontrolu kupcima o tome kome će i koje privatne podatke dijeliti.

3.4. Načini korištenja velikih podataka

Marketinški stručnjaci mogu primjenjivati velike podatke u marketingu na nekoliko različitih načina. U svom radu, Spancer (2014.) ističe pet načina na koji marketinški stručnjaci mogu koristiti velike podatke u svojoj strategiji, a to su:

- **Pratiti Google trendove** – google trendovi su jedan od najpristupačnijih načina korištenja velikih podataka. Oni prikazuju teme u trendu kvalifikacijom koliko često je određen pojam se unosi odnosno pretražuje u odnosu na ukupni volumen pretraživanja. Globalni marketinški stručnjaci pomoću toga mogu procijeniti popularnost određenih tema za koje su sigurni da bi bili zainteresirani njihovi kupci.
- **Koristiti digitalne informacije** – odnosi se na korištenje puno analitike kako bi saznali više o ciljanim kupcima, točnije kako stvoriti idealne profile kupaca. Danas marketinški stručnjaci posjeduju razne intelektualne činjenice kojima mogu dokazati svoje intuicije i rasvijetliti sve u detalje, kao što su: koje web stranice korisnici najčešće posjećuju, koje profile na društvenim mrežama imaju pa čak i koje mjesto kliknu na određenoj web stranici.

- **Personalizirati u stvarnom vremenu** – marketinški stručnjaci trebaju poslati pravu poruku u pravo vrijeme. Pravovremenost i relevantnost su temelj uspješne kampanje i uspješnog angažmana potrošača s robnom markom. Privezivanje digitalnog ponašanja u CRM sustave omogućuje praćenje tema za koje su kupci najviše zainteresirani i na temelju toga im se mogu slati sadržaji koji imaju najviše smisla za razvoj ideja.
- **Identificirati specifičan sadržaj** – odnosi se na onaj sadržaj kojim se nastoji kupca pogurnuti dalje u prodajnom toku. Alati za bodovanje sadržaja mogu pokazati koji dio sadržaja je bio uspješan u sklopu zaključenog posla. To dopušta marketingu da brusi strategiju oko sadržaja koji najčešće rezoniraju sa njihovim kupcima i prisiljavaju ih na kupnju.
- **Integrirati predviđajuću analitiku** – marketinški stručnjaci vide visoku stopu uspjeha u bodovanju predviđanja. Preko osnovne CRM baze i drugih internet podataka sa treće strane generira se model koji uspješno predviđa budućnost ponašanja.

Paine (bez dat.) navodi kako danas marketinški stručnjaci sve više koriste umjetnu inteligenciju i strojno učenje kako bi analizirali ogromne količine podataka. Oni čak koriste prediktivne metode odnosno analitiku kako bi saznali izgled u budućnosti, donijeli zaključke i prilagodili komunikaciju. Drugim riječima marketinški stručnjaci bolje razumiju što ljudi rade na web stranicama i personalizacija je jednostavnija nego ikad prije. U nastavku su opisani glavni slučajevi upotrebe velikih podataka u marketingu, a to su:

- **Bolje ciljano oglašavanje** – budući da izdavači prikupljaju podatke o posjetiteljima, to im omogućuje da imaju relevantnije oglašavanje. Kako Google i Facebook nude detaljnije ciljane ponude, tako i prodavači na trećoj strani također mogu ponuditi tu opciju.
- **Semantičko pretraživanje** – to je proces u koje se traži prirodni jezični pojmovi. Veliki podaci i strojno učenje olakšavaju tražilicama da u potpunosti razumiju što korisnik traži, a marketinški stručnjaci počinju to uključivati u funkciju pretraživanja kako bi se poboljšalo korisničko iskustvo.
- **Više relevantan sadržaj** – može se vrlo jasno prikazati na primjeru Netflix-a koji prikuplja velike količine korisničkih podataka kako bi stvorio bolje personalizirane preporuke svojim korisnicima.
- **Uvjerljivije testiranje** – činjenica prikupljanja i analiziranja podatka u velikim količinama omogućuje provođenje puno više testiranja umjesto provođenja testiranja

varijante samo jednog faktora. Marketinški stručnjaci upotrebljavaju uvide kako bi prilagodili web mjesta, odnosno učinili ih privlačnijima ciljanoj publici.

- **Strojna analitika** – uvijet će postojati povezanost čovjeka i tehnologije prilikom analize velikih skupova podataka, jer jednostavno jedno bez drugog ne može ići.

Columbus (2016.) smatra kako veliki podaci pružaju uvid koji sadržaj je najučinkovitiji u određenoj fazi prodajnog ciklusa. Također navodi nekoliko područja u kojima korištenje velikih podataka unaprijeđuje marketing i prodaju, a to su:

- Razvijanje strategija određivanja cijena na razini kupca i njihovo optimiziranje postaje sve dostupnije.
- Veliki podaci revolucioniziraju kako tvrtke postižu veće stope odgovora kupaca i stječu veći uvid u klijente.
- Analiza klijenata, operativna analitika, prijevare i sukladnosti, novi proizvodi i usluge te optimizacija skladišta podataka su slučajevi korištenja podataka u marketingu i prodaji.
- Uz pomoć velikih podataka i tehnologije moguće je ugraditi inteligenciju u kontekstualni marketing.
- Analiza velikih podataka povećava sposobnost marketinških stručnjaka da izvedu kampanju i usredotoče se na to kako učiniti odnose uspješnijima.
- Korištenje velikih podataka i napredne analitike omogućuje veći angažman kupaca i postizanje veće lojalnosti.
- Veliki podaci omogućuju poduzećima da steknu bolje uvide u svim pokretačima njihovog poslovanja.
- Analiza kupčeve vrijednosti koja se temelji na velikim podacima omogućava poduzećima da daju dosljedna iskustva kroz sve kanale u poduzeću.

4.Strategija upravljanja zadovoljstvom kupaca

Kupac je fizička ili pravna osoba kojoj se prodaju proizvodi ili usluge. Zadovoljstvo kupca je osobni stav o tome u koliko mjeri je proizvod ispunio njegova očekivanja i zahtjeve. Svakom poduzeću bilo bi dobro pratiti razinu zadovoljstva zbog toga što je to jedan od razloga njegovog opstanka na tržištu. Praćenje zadovoljstva također je bitno zbog konstantnog pronalaženja novih kupaca i zadržavanja starih. Upravljanje zadovoljstvom je ključan dio poslovanja jer zadovoljni kupci su ti koji više troše i spremniji su komunikacijom pomoći u poboljšanju postojećih proizvoda i usluga.

Vranešević (2000.) definira zadovoljstvo kao pozitivni osjećaj o proizvodu ili usluzi, kojeg je upotrijebio i koji mu kao takav daje potvrdu o tome da je obavio uspješnu transakciju, odnosno da je donio ispravnu odluku kada je birao između različitih vrsta proizvoda. Ujedno, to govori i o ispunjenju njegove potrebe.

Barbir i suradnici (2011.) govore o tome kako je zadovoljstvo osnovni element vjernosti kupaca. U slučaju nepostojanja tog zadovoljstva poduzeće ne može ostvariti dugotrajnije odnose sa svojim klijentima koji je ključan u daljnjem poslovanju.

Grigoroudis i Siskos (2010.) ističu kako se zadovoljstvo kupca može definirati na dva načina i to kao rezultat ili proces. Kao rezultat zadovoljstvo se odnosi na konačno stanje koje kupac ostvari kroz kupnje ili ne ostvari u slučaju kada nije zadovoljan. Zadovoljstvo kao proces odnosi se na niz različitih psiholoških i percipitivnih procesa koji pridonose stvaranju zadovoljstva.

Dobrić i Gregurec (2016.) navode kako je zadovoljstvo jedan od najvažnijih koncepata današnjice jer on povezuje proces kupnje i potrošnje, odnosno preko postprodajnog procesa kreiraju se stavovi, stvara lojalnost i ponavljanje kupnje. Odnosno zadovoljstvo je ispunjenje nekog očekivanja i održavanje pozitivnih stavova koji poduzećima omogućuju stvaranje boljih i dugotrajnijih odnosa sa kupcima.

Oliver (2010.) definira zadovoljstvo kao odgovor na ispunjenje potrošača. Drugim riječima, to je prosudba da je značajka proizvoda ili usluge pružila ugodnu razinu potrošnje, uključujući i razine podmirenja ili prekoračenja.

Muller i Srića (2005.) ističu važnost zadovoljstva kroz narodnu mudrost da se dobar glas daleko čuje, a loš još dalje. Brojna istraživanja dovela su do shvaćanja poduzeća da moraju saznati što više informacija o svojim kupcima te ih primijeniti za personaliziranje usluge. Tvrtke koje postignu veće stope zadovoljstva svojih kupaca ostvarit će brojne pogodnosti, a

to su: veća vjernost klijenata, manja osjetljivost na rat cijenama, manji troškovi marketinga, veća dobit i slično.

Gutić, Bačelić i Bačelić (2011.) govore kako je zadovoljstvo kupca funkcija između njegovog očekivanja za određeni proizvod i učinka kojeg kupac postiže s proizvodom u upotrebi. Svaki kupac teži maksimalizaciji svog zadovoljstva i upravo zbog tog razloga on će odabrati onog ponuđača koji mu nudi maksimalne koristi od proizvoda ili usluge.

Zadovoljan potrošač će najvjerojatnije preporučiti proizvod drugima što znatno utječe na nastajanje i jačanje pozitivnih stavova potrošača prema tom proizvodu. Također sasvim je izvjesno da će zadovoljan potrošač ponovo doći i kupiti taj isti proizvod. Kod nezadovoljnog potrošača sve ovisi o vrsti i stupnju. On najčešće širi negativne informacije u okruženju i tako stvara negativne stavove. Ponekad će potrošač pokušati vratiti taj proizvod i biti će sklon prijavama, pritužbama i slično. (Gutić i sur., 2011.)

Raab, Ajami, Gargeya i Goddard (2008.) definiraju zadovoljstvo kupaca kao stupanj korespondencije između očekivanja koju potencijalni kupac ima za proizvod ili percipiranu uslugu koja se zapravo pruža.

Kesić (1999.) navodi kako se zadovoljstvo odnosi na nagradu koja proizlazi iz korištenja proizvoda i ona se najčešće poklapa sa kupčevim očekivanjima. Ta očekivanja se formiraju prije same kupnje i mogu se odnositi na prirodu i performansu proizvoda, troškove te društvene koristi.

U procesu postizanja zadovoljstva ne postoji direktna korelacija s očekivanjima. Kao posredna varijabla javlja se poslijekupovno odobravanje. To odobravanje povezano je sa zadovoljstvom kupca s odabranom markom, a neodobravanje sa nezadovoljstvom. Što znači da u potrošač koristi dva kriterija za vrednovanje rezultata. Prvi je objektivno vrednovanje, a drugo emocionalno u kojem kupac mjeri emocionalne komponente. Ako nema poveznosti između ta dva kriterija, vrednovanje će biti nejasno. (Kesić, 1999.)

Zadovoljstvo je ključan faktor koji može utjecati na poslovanje svakog poduzeća te iz tog razloga, Kierczak (bez dat.) govori kako je vrlo važno pratiti zadovoljstvo kao faktor i unaprijediti ga kako bi podigli razinu lojalnosti. Zadovoljstvo je iznimno važno jer ako ne brinemo za kupce, ne trebamo ni očekivati da oni brinu za naše proizvode ili usluge.

4.1. Istraživanje zadovoljstva

Važno je da poduzeće i njegovi kupci postanu partneri u poslovanju. Analiziranjem različitih percipiranja poduzeća i proizvoda, moguće je prikupiti sve korisne informacije koje se koriste u daljnjem provođenju strategije. Takve informacije pomažu poduzeću u rješavanju problema

koji znatno koče stvaranje zadovoljstva u obostranu korist. Zadovoljstvo nije nešto što dođe preko noći, već koncept koji se postupno gradi godinama uz puno truda i pažnje.

Gutić i sur. (2011.) govore o tome kako je istraživanje zadovoljstva bit svih segmenata istraživanja tržišta i marketinga. Ustvari to je sinonim za istraživanje tržišta. Zadovoljstvo kupaca je vrlo složen i nije ga lako istraživati. Još uvijek ne postoje metode i postupci kojima je to moguće kompleksno postići te umjesto toga danas se koriste različite parcijalne metode i postupci koje daju samo različite poglede na zadovoljstvo.

Na to se nadovezuje, Vranešević (2000.) koji naglašava kako istraživanje zadovoljstva mora biti organizirano kao proces koji se provlači kroz nekoliko faza. Također mora biti kontinuiran i za vrijeme njegovog provođenja moguće je otkriti nove spoznaje. Važno je da svaka tvrtka razvije taj proces prema svojim osobnim ciljevima i mogućnostima. Proces istraživanja obuhvaća faze kao što su određivanje ciljeva, odabir vrste istraživanja, prikupljanje podataka, obrada i analiza podataka te njihovo korištenje u provođenju postavljenije strategije.

4.1.1.Određivanje ciljeva istraživanja

Ključni prvi korak u istraživanju zadovoljstva. Među ciljeve koji se određuju u ovom koraku spadaju: (Vranešević,2000.,str. 204-205)

- Približavanje kupcima s ciljem da im se da osjećaj važnosti i osigura povratna veza
- Uspostavljanje prioriteta i poduzimanje akcija
- Mjerenje unaprijedivanja usporedbom prikupljenih podataka
- Identificiranje konkuretnskih prednosti
- Praćenje i predviđanje uspješnosti tvrtke
- Mjerenje unaprijeđenja tijekom vremena

U istraživanje zadovoljstva osim stručnog osoblja koje je zaduženo za taj proces bilo bi poželjno i uključivanje i ljudi na rukovodećim pozicijama koji mogu znatno utjecati i pomoći istraživačkom timu u razvijanju liste kupaca. Zbog toga što je istraživanje zadovoljstva kontinuirani proces nema potrebe za istraživanjem vrijednosti u svakom valu istraživanja. Vrlo je važno tu vrijednost provjeravati u definiranim vremenskim razmacima kako bi utvrdili da li se istražuju značajke i dimenzije proizvoda koji određuju tu vrijednost. (Vranešević,2000.)

4.1.2.Vrste prikupljanja podataka

Vrlo je važno odabrati pravi način kontaktiranja kupaca. Na taj odabir utječu različiti faktori kao što su zemljopisna raspršenost, potreba za poznavanje identiteta, složenost zahtijevanih informacija, količina podrške koju je potrebnu pružiti, brzina kojima se podaci prikupljaju i

slično. Svaki oblik kontaktiranja važno je uskladiti sa pravilnim segmentom kupaca. Tu spadaju metode kao što su: (Vranešević,2000.)

1. **Osobno ispitivanje** – metoda u kojoj ispitivač osobnim kontaktom objašnjava svrhu ispitivanja, postavlja pitanja i unosi dobivene odgovore. Ispitivač ovom metodom može ispitivati samo jednog ili skupinu ispitanika. Ispitivač kao osoba koja provodi ispitivanje ima za zadatak pronaći ispitanika, provesti anketu te dostaviti popunjenu anketu službi koja provodi istraživanje.
2. **Kontakt putem pošte** – metoda u kojoj ispitanik nakon ispunjavanja, anketu vraća poštom. Prednost ove metode je u tome što nema ispitivača koji svojom nazočnošću može utjecati na odgovore dok je nedostatak ove metode nemogućnost predviđanja povratnih informacija.
3. **Telefonsko ispitivanje** – ova metoda je znatno jeftinija od ostalih. Puno je jednostavnije kontaktirati ispitanika. Velika prednost ove metode se pojavljuje prilikom samog ispitivanja jer je ispitivač tijekom razgovora cijelo vrijeme prisutan i spreman pomoći i pojasniti određena pitanja ispitaniku. Glavni nedostatak ove metode je slaba rasprostranjenost mreže.
4. **Kombinirani načini** – ponekad je poželjno kombinirati određene metode kako bi se ostvario željeni učinak.

4.2. Analiza podataka o zadovoljstvu

Analiza zadovoljstva kupaca sastoji se od niza ulaznih podataka koji se kasnije detaljno analiziraju. Vrlo je važno kvalitetno istražiti i proučiti stavove, želje i potrebe kupaca kako bi se bolje ocjenilo zadovoljstvo. Zadovoljstvo se razlikuje od segmenta do segmenta pa je s toga vrlo važno podijeliti kupce u pripadajuće segmente kako bi se potrebna vrsta zadovoljstva preciznije analizirala. Ako segmenti nisu pravilno postavljeni, na kraju i sama analiza zadovoljstva neće biti obećavajuća.

Da bi imali koristi od podataka koje istražujemo, mjerenja moraju biti organizirana na način da je u osnovi podataka moguće doći do zaključka. Priprema podataka za obradu na računalu može se promatrati kroz aktivnosti kao što su kategoriziranje, editiranje, kodiranje, unos podataka i kontrola. U kategoriziranju svaka skupina podataka mora biti pravilno svrstana u određene kategorije. Te kategorije moraju biti dobro objašnjene jer se time olakšava ispitaniku davanje odgovora što na kraju olakšava ostale faze u tom procesu. Krajnji rezultat kategoriziranja je smanjenje troškova te etape u procesu i cjelokupnog istraživanja. U

procesu kategoriziranja važno je se pridržavati pravila sličnosti, različitosti i isključivosti te potpunosti (Vranešević,2000.)

Editiranje se odnosi na pregledavanje i ispravljanje pogrešaka kod prikupljenih podataka s ciljem postizanja veće točnosti. Editiranje je najbolje provoditi odmah po prikupljanju podataka, pa i za vrijeme prikupljanja podataka, točnije prilikom vraćanja upitnika. Ako se problemi ne otklone na vrijeme to može znatno utjecati na točnost analize podataka. Prilikom editiranja postoje pravila koja se trebaju poštovati, a to su : (Vranešević,2000.)

- **Čitljivost** – podaci moraju biti čitljivi kako bi se mogli koristiti za daljni rad. Ponekad ispitanik zaokruži više kategorija odgovora jer misli da će mu to pomoći u dostizanju točnog odgovora.
- **Potpunost** – kada se radi o strukturiranom upitniku, tada prazni odgovori mogu signalizirati propuste. Moguće su tri pogreške, prva je to da ti prazni odgovori mogu značiti da je ispitivač zaboravio postaviti pitanja ili je ispitanik zaboravio dati odgovor, drugo je to da se možda mislilo kako ta pitanja nisu važna i treće da ispitanik nije želio odgovoriti na pitanja.
- **Dosljednost** – ako odgovori u upitniku nisu dosljedni tada se sumnja na ispravnost čitavog upitnika. Ispitivač je odgovoran i dužan upozoriti ispitanika na nedosljednost te ga zamoliti da razmisli prilikom davanja odgovora na pitanja.
- **Točnost** – osoba koja se bavi editiranjem dužna je provjeriti postoji li bilo kakvo ponavljanje odgovora kod većeg broja ispitanika.

Treća etapa je kodiranje. Kodiranje se sastoji od označavanja kodova u upitniku ovisno o ispitanikovu odgovoru. Postoji prijekodiranje i poslijekodiranje. Prijekodiranje je kad se unaprijed određuju kodovi za svako pitanje, dok je poslijekodiranje naknadno kodiranje u kojem se različitim odgovorima daju kodovi poslije ispitivanja. Za kodiranje je potrebno iskustvo i nadzor. Toj etapi važno je pristupiti pažljivo jer svaka greška znatno otežava daljnje provođenje analize. Posljednja faza je unos i kontrola podataka (Vranešević,2000.)

4.2.1.Obrada i analiziranje podataka

Podaci za istraživanje zadovoljstva analiziraju se i obrađuju na isti način kao i podaci za neku drugu vrstu istraživanja. Na to, Vranešević (2000.) ističe kako prikupljeni podaci moraju biti u prikladnom obliku te tijekom procesa analize podataka potrebno je biti siguran da će se ovisno o fazi procesa znati odgovoriti na određena pitanja. Analizu podataka potrebno je odrediti prije pokretanja istraživanja, ovisno o odabranoj analizi projektira se upitnik, određuje se način kontaktiranja, veličina uzorka i odabir ispitanika u uzorku. Nakon analize slijedi pisanje izvještaja koji se sastoji od svih zaključaka, preporuka te poduzimanja akcija koje su

provedene tijekom istraživanja. Za dobru analizu potrebno je imati znanje, iskustvo i intuiciju. Osnovni koraci na početku procesa analiziranja su: osnovna analiza, izračunavanje mjera centralne tendencije, potvrda opravdanosti postavljenih hipoteza i po potrebi određivanje hipoteza i donošenje zaključaka o važnosti pojedinih varijabli.

4.3. Mjerenje zadovoljstva

Zadovoljstvo kupaca je ključan faktor u uspješnosti poslovanja. Zadovoljstvo nastaje ostvarivanjem postavljenog očekivanja kupca. Postizanje zadovoljstva će stvoriti pozitivna razmišljanja koja će se širiti velikom brzinom. Poduzeća moraju stvoriti reputaciju i djelovati na temelju tog zadovoljstva te konstatno poboljšavati odnose s kupcima, s ciljem zadovoljavanja njihovih želja i potreba jer gubitak samo jednog kupca može izazvati lančanu reakciju koja ni u kojem slučaju neće biti povoljna za poduzeće i njegovo daljnje poslovanje.

Uz to, Dobrinić i Gregurec (2016.) ističu kako je poželjno mjeriti zadovoljstvo kupaca jer se to smatra ključnim faktorom zadržavanja. Zadovoljan kupac koji širi pozitivne stavove o proizvodima i uslugama, ostaje lojalan, ponavlja kupnju, manje je osjetljiv na cijenu i slično.

Gutić i sur. (kao što citira Kotler) govore kako se praćenje zadovoljstva klijenata može mjeriti na četiri načina, a to su:

1. Sustavno praćenje žalbi i sugestija kupaca
2. Ispitivanje kupaca o njihovom zadovoljstvu
3. Metoda tajanstvene kupnje
4. Analiza izgubljenih kupaca

1.Sustav praćenja žalbi i sugestija

Žalbe i pritužbe, ali i sugestije kupaca treba stalno pratiti i registrirati. To su prilike da poduzeće ispravi svoje pogreške. To treba biti kontinuiran posao preko kojeg će kupci steći sigurnost da će njihove žalbe i sugestije biti ozbiljno razmotrene i da će na kraju se to popraviti u njihovo korist. (Gutić i sur.,2011.)

Vranešević (2000.) ističe važnost brzog ispravljanja pogreške koja je dobivena od strane kupca. Kupcima kojima se problem riješi u brzom roku, iskazuju znatno veću lojalnost. Također prilikom uspostavljanja ovog sustava važno je skrenuti pozornost na informacije koje je potrebno proslijediti svim odjelima, zatim osoblju koje prima pritužbe jer mora biti sposobno odmah rješavati probleme i zaposlenicima koji prikupljaju pritužbe.

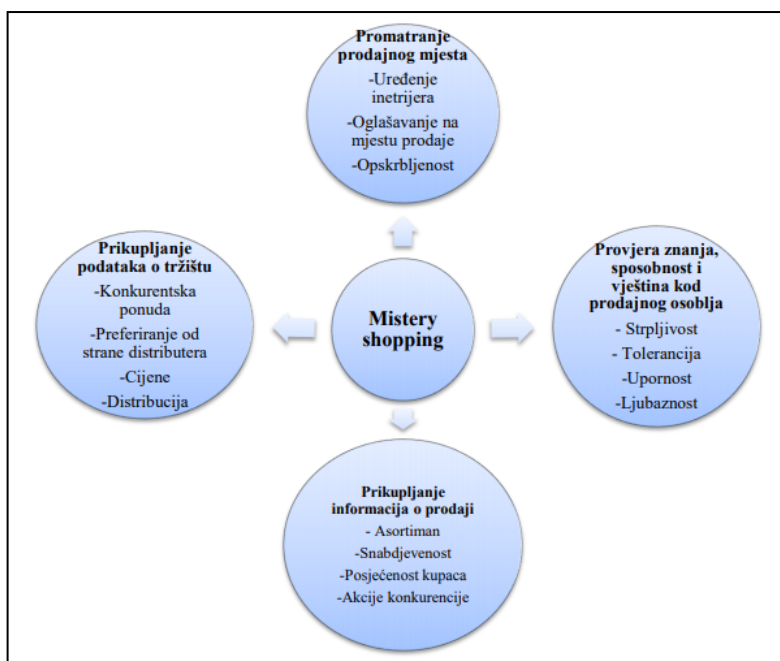
2. Ispitivanje kupaca o njihovom zadovoljstvu

Poduzeća koja su usmjerena na kupce i njihovo zadovoljstvo, šalju ankete ili obavljaju telefonske pozive kako bi se saznalo što kupci misle o poslovanju poduzeća. Ovakav način prikupljanja podataka o zadovoljstvu je čisti eksterni izvor, te se gleda kao proces koji se sastoji od nekoliko koraka. (Dobrinić, Gregurec, 2016.)

3. Metoda tajanstvene kupnje

Tehnika u kojoj se tajanstvena osoba predstavlja kao kupac i prolazi cijeli kupovni proces. Ta osoba ima namjeru prikupiti podatke o odnosu poduzeća sa kupcima. Metoda je ograničena i odnosi se samo na ponašanje prodajnog osoblja prema kupcima. (Gutić i sur., 2011.)

Drugim riječima, Vranešević (2000.) smatra kako se ova metoda uglavnom koristi za mjerenje uspješnosti na prodajnim mjestima. Cilj je što više uočiti dobre i loše stvari u kupovnom procesu. Tajanstveni kupac mora biti dobro obučen da zapaža stvari, da ih pamti i da nakon same kupnje evidentira analizirane stvari.



Slika 6. Sadržaj metode tajne kupnje (Izvor: D.Gutić,J.Bačelić,Z.Bačelić,2011)

4. Analiza izgubljenih kupaca

Gutić i sur. (2011.) govore o tome kako se ova metoda sastoji od kontaktiranja bivših kupaca s ciljem utvrđivanja razloga odlaska odnosno prestanka kupovanja proizvoda. Osim tih podataka ovom metodom može se doći i do podataka na koji način poduzeće može ponovo vratiti te izgubljene kupce. Često bivši kupci i nisu spremni odazvati se ispitivanju iz kumuliranog nezadovoljstva prema poduzeću.

Problem se pojavljuje kod pravodobnog otkrivanja kupaca koji su u procesu napuštanja ili su već napustili poduzeće. Stopa gubitaka je također važan faktor koji bi bilo poželjno promatrati iz razloga što on pokazuje u kojoj mjeri poduzeće ne uspijeva zadovoljiti svoje kupce. (Dobrinić, Gregurec, 2016.)

Barrett (2016.) spominje da ako se ankete o zadovoljstvu koriste na pravilan način, to može omogućiti poduzećima da dođu do podataka o razini sreće svojih kupaca. Također uz to navodi tri načina na koji se može mjeriti razina zadovoljstva, a to su:

1. **Uporaba pravilnih anketnih alata** – prosječan kupac treba izuzetan razlog za dijeljenje povratnih informacija. Ako ankete poduzeća ne potiču ljude na odgovore tada će poduzeće samo čuti one najzadovoljnije i najnezadovoljnije kupce što će rezultirati time da podaci koji su dobiveni anketom velikom većinom neće upozoravati na probleme. To se rješava na način da se kupcima olakša odgovaranje ili da se koriste mobilne ankete.
2. **Optimizacija za veće stope odgovora** – istraživanje zadovoljstva ne čini puno bez pouzdanih podataka. Stope odgovora ne ovise samo o duljini i upitnim fraziranjima, već je potrebno optimizirati anketu, prilagoditi njezin dizajn te poboljšati način njezine distribucije.
3. **Prikupljanje i analiziranje podataka** – nakon slanja anketa, važno je uvijek temeljito analizirati podatke kako bi se generirali korisni uvidi u kupce.

Smith (2014.) smatra kako je zadovoljstvo teško izmjeriti zbog nekoliko razloga. Računati na zadovoljstvo kupaca zbog povrata informacija nije slučaj jer većina ljudi voli šutjeti da su zadovoljni. Neki ljudi pak ne vide potrebu u komuniciranju s davateljem usluga, dok drugi nastoje prijeći preko pritužbi. Postavljanje standarda i poboljšavanje odnosa zaposlenika sa kupcima je glavna strategija mjerenja zadovoljstva i osiguranja uspjeha. Neki od načina mjerenja zadovoljstva su:

- **Ankete** – anketiranje korisnika je možda jedini način za dobivanje povratnih informacija, osim ako se oni sami ne jave. Osim toga to je i najčešće korišten način analiziranja zadovoljstva. Većina ljudi je zauzeta i nema vremena za ispravke. Ankete se mogu pružiti putem nekoliko način, kao što su e-pošta i telefonski pozivi.
- **Razumjeti očekivanja** – važno je razumijeti što kupci očekuju jer time se mogu zadovoljiti njihova očekivanja pružajući im ugodniju uslugu ili proizvod. Sve s ciljem zadovoljavanja njihovih potreba.
- **Saznati nedostatke** – u situacijama ne ispunjavanja zahtjeva kupaca, bilo bi lijepo saznati što je u djelovanju pogrešno. Potrebno je saznati da li su zaposlenici dali

obećanja koja ne mogu ispuniti, upoznati lanac komunikacije radi saznanja gdje se nalaze kvarovi te krenuti sa izmjenama.

- **Odrediti specifičnosti** – bez obzira da li je kupac zadovoljen ili nije, potrebno je prikupiti informacije za procjenu situacije. Potrebno je prikupiti informacije o tome što su kupci kupili, što im se svidjelo, što im se nije svidjelo, o očekivanjima kupnje i prijedloge za poboljšanja.
- **Procjeniti konkurenciju** – poželjno je imati inicijativu kako bi se saznalo zašto kupci cijene druge marke više nego ostale.
- **Mjerenje emocionalnog aspekta** – važno je povezati povratne informacije kupaca s kvalitetom, pouzdanošću i opsegom zadovoljstva. Komentari koje kupci daju su mjerilo njihova zadovoljstva. Kupci koji pokazuju nezadovoljstvo potiču promjenu strategije.
- **Mjerenje lojalnosti** – lojalnost je vjerojatnost ponovne kupnje proizvoda ili usluge. Sveukupno zadovoljstvo, preporuka i ponovna kupnja su pokazatelji zadovoljstva kupaca.
- **Nadgledanje** – praćenje se može usmjeriti na telefonske, e-mail i chat komunikaciju. Najčešće uključuje telefonske interakcije osmišljene od strane poduzeća.
- **Kartice za povratne informacije** – pomažu u procjeni komentara kupaca.

Raab i sur. (2008.) navode kako je cilj mjerenja zadovoljstva predstavljanje situacije kupca što je objektivnije i sveobuhvatnije moguće. Također navode kako je mjerenje zadovoljstva moguće podijeliti u osam faza, a to su:

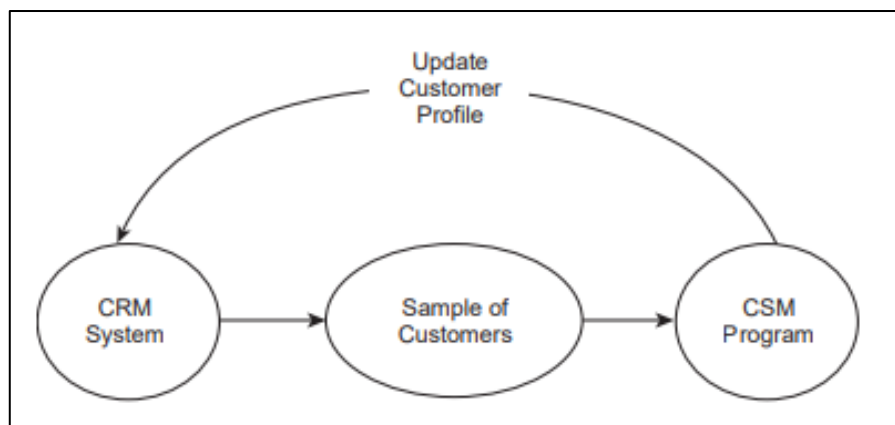
1. **Osnivanje predmeta i cilja proučavanja** – u ovoj fazi određuje se tko bi trebao biti anketiran. Važno je da se uključe postojeći kupci, bivši kupci i kupci konkurencije. Za različite skupine postoji različiti ciljevi istraživanja.
2. **Istraživačka faza** – sastoji se od rasprava s kupcima, tijekom kojih treba otkriti očekivanja kupaca. Iz te analize dolazi se do spoznaja koje pomažu u dizajniranju i izboru odgovarajućih metoda istraživanja.
3. **Izbor i dizaj** – u ovoj fazi donose se odluke o vrsti ankete koja će se primjenjivati, zatim metodi ankete i obliku pitanja koja će se nalaziti u anketi.
4. **Prijetestna faza** – u ovoj fazi bira se metoda ispitivanja na malom broju kupaca. Ako se u ovoj fazi pojave nedostaci, onda je potrebno preoblikovati metodu.

5. **Implementacija** – u ovoj fazi se provodi studij. Prije stvarnog mjerenja, kupac bi trebao biti obaviješten pismom da će doći do anketiranja. Na taj način, smanjuje se udaljenost između ispitivača i ispitanika, a motivacija za suradnju se povećava.
6. **Analiza podataka** – glavni cilj analize je utvrđivanje slabih točki te njihovo otklanjanje putem raznih poboljšanja.
7. **Formuliranje plana djelovanja** – na temelju procijenjenih podataka kreće se u određivanje odgovarajuće akcije kojom će se povećati zadovoljstvo.
8. **Provedba plana djelovanja** – provedeni plan treba redovito pregledavati i analizirati s obzirom na njegov uspjeh ili neuspjeh.

4.4. CRM i zadovoljstvo kupaca

CRM igra važnu ulogu u poticanju zadovoljstva pa s toga, Agarwal (2012.) govori o tome kako su zadovoljni kupci profitabilni za poduzeće ne samo iz razloga što će možda ponoviti kupnju, nego i iz razloga što oni poduzeće promiču riječima svojim prijateljima i slično. Drugim riječima, CRM poboljšava tržišni udjel poduzeća tako što uvodi više kupaca u poduzeće. Međutim bez pravilne implementacije CRM sustava nema ni zadovoljstva kupaca. CRM sustav kao takav propisuje da kako bi zadovoljili kupce, prvo ih je potrebno razumijeti. Kupci bi trebali biti shvaćeni na temelju njihovih ukusa, stavova, preferencija i čimbenika na temelju kojih odlučuju. Niti jedno poduzeće ne može pružiti usluge svim svojim kupcima na zadovoljavajući način, pa je iz tog razloga potrebno pravilno identificirati ciljano tržište.

Allen (2004.) navodi kako postoji veza između CRM sustava i zadovoljstva, odnosno mjernih programa za zadovoljstvo kupaca (CSM). To je najbolje objasniti pomoću slike koja prikazuje dvorstuku prirodu tog odnosa. Jasno je vidljivo kako CRM sustav generira uzorke kupaca za program zadovoljstva. Nakon toga podaci o povratnim informacijama kupaca se zapisuju u CRM sustav naravno uz uvjet da je to dopušteno od strane kupca odnosno ispitanika. Uzdužna analiza CSM podataka može poslužiti kao procjena performansi CRM sustava. Uostalom, svako poduzeće koje u potpunosti nastoji obuhvatiti strateške i operativne razine sa CRM sustavom će u konačnici doživjeti povećanje razine zadovoljstva kupaca.



Slika 7. Povezanost CRM-a i CSM-a (Izvor: Allen,2004.)

Hassan,Nawaz,Lashari i Zafar (2015.) ističu kako upravljanje odnosima s kupcima ima značajan utjecaj na zadovoljstvo kupaca te da obje varijable imaju pozitivan odnos. Jak CRM sustav potaknuti će kupce da budu zadovoljniji i zadrže odnose s poduzećem. CRM povećava tržišni udio, produktivnost, moral zaposlenika, poboljšava dubinsko znanje o kupcima što na kraju rezultira povećanim zadovoljstvom kupaca, stvaranjem lojalnosti te boljim shvaćanjem što kupci žele.

Long, Khalafinezhad, Ismail i Rasid (2013.) smatraju kako CRM ima pozitivan odnos sa ovisnim varijablama odnosno zadovoljstvom i lojalnošću. Međutim, ne mora značiti da svi elementi imaju utjecaj na te dvije varijable. Ponašanje zaposlenika i razvoj odnosa najviše ima utjecaj na zadovoljstvo korisnika.

Poduzeća moraju staviti naglasak na ta dva faktora. Od zaposlenika se očekuje ne samo da budu ljubazni prema kupcima, već moraju posjedovati znanja od proizvodima te određene komunikacije vještine. Razvoj odnosa može se poboljšati kroz nekoliko metoda, a to su : obaviještavanje korisnika o promocijama, poticanje kupaca da kupuju više pokazivajući im zahvalnost te uvjeravanje kako su kupčeve povratne informacije ozbiljno shvaćene i korištene u prave svrhe. (Long i sur.,2013.)

5.Upravljanje i organizacija CRM-a

Kupac je kralj i svi u poduzeću bi trebali biti fokusirani na stvaranje vrijednosti prema kupcu. U tome nam pomaže upravo CRM koji je danas postao neizostavan dio modernog poslovanja. CRM kao poslovna strategija u centar pažnje stavlja upravo kupce i njihove potrebe. Takva strategija ima za cilj uspostavljanje odnosa i upravljanje važnim informacijama. Zajedno sa prikupljanjem i pohranjivanjem velikih podataka osigurava kompletne informacije o svakom kupcu i na taj način pomaže poduzeću u kontroliranju prodaje.

To potvrđuje, Phelps (2008.) koji definira CRM kao način shvaćanja svakog kupca kao individualca te da on ima određeni izbor. CRM gleda kako svakog kupca tretirati kao pojedinca te njegov pozitivni izbor iskoristiti u korist poduzeća. Osim toga obuhvaća još trenutne marketinške aktivnosti i metode upravljanja kao što su lojalnost kupaca i marketing baza podataka. Postoje tri temeljna elementa koja treba uzeti u obzir prilikom usklađivanja poslovanja sa formatom odnosa prema kupcima. Prvi se odnosi na zadržavanje, drugi je razvijanje kupčevog potencijala, a treći "odbijanje" onih koji ne mogu ponuditi vrijednost na duže vrijeme.

Kerr i Anderson (2002.) navode kako je CRM sveobuhvatan pristup za stvaranje, održavanje i širenje odnosa s kupcima. Ta definicija proteže se kroz ti ključne riječi. Prva je sveobuhvatnost, što znači da CRM ne pripada samo prodaji i marketingu. Nije isključiva odgovornost korisničke službe, niti je zamisao tehnološkog tima. CRM mora biti način poslovanja koji dodiruje sva područja organizacije. Druga ključna riječ odnosi se na pristup što znači način tretiranja nekog ili nečeg. Zadnji dio sastoji se od tri riječi, a to su stvaranje, održavanje i širenje što znači da je CRM ciklus koji kruži oko kupaca.

Raab i sur. (2008.) spominju kako uspješni CRM programi omogućuju velikim i malim tvrtkama kako bi postigli učinkovitost koja ne bi bila moguća u okruženju koje ne uključuje točan, pravovremen i neprekidan povratni mehanizam koji je potreban za predviđanje budućih potreba i želja kupaca. Ako tvrtke pravilno implementiraju CRM sustav mogu ostvariti tri glavne kompetitivne prednosti, a to su: globalna učinkovitost, fleksibilnost na više tržišta te učenje širom svijeta.

Buttle i Maklan (2015.) definiraju CRM kao temeljnu poslovnu strategiju koja integrira interne procese i funkcije, te vanjske mreže, za stvaranje i isporuku vrijednosti ciljanim kupcima. Temelji se na visokokvalitetnim podacima vezanim uz kupce i djeluje zajedno sa informacijskom tehnologijom.

Dobrinčić i Gregurec (2016.) govore o tome kako je CRM, strategija koja se brzo razvila u cijelom svijetu te se smatra vrlo novim načinom djelovanja poduzeća s ciljem podizanja suradnje između poduzeća i kupaca. Osnova ideja je razviti strategije za privlačenje pravih kupaca i optimizirati životne vrijednosti krzo povećanje lojalnosti.

Kumar i Reinartz (2012.) definiraju CRM kao praksu analize i korištenja marketinga baza podataka i komunikacijske tehnologije za određivanje korporativne prakse i metoda koje maksimiziraju životnu vrijednost svakog kupca s kojim poduzeće posluje.

Dyché (2001.) smatra kako je CRM infrastruktura koja omogućuje određivanje i povećanje vrijednosti kupaca, odnosno motivira kupce da ostanu lojalni i ponavljaju kupnje. On ima potencijal za promjenu odnosa kupaca s poduzećem i konačno povećanje prihoda.

Caufield (2001.) definira CRM kao interaktivni proces za postizanje optimalne ravnoteže između korporativnih ulaganja i zadovoljstva potreba kupaca uz generiranje maksimalne dobiti. CRM uključuje mjerenje svih inputa kroz sve funkcije, stjecanje i kontinuirano ažuriranje znanja o kupcima, poboljšavanje performansi primjenom znanja o kupcima, integriranje aktivnosti, provedbu odgovarajućeg sustava za potporu i stalno balansiranje inputa i potreba kupaca.

Cunningham (2002.) navodi kako je pojam CRM opisan kao interakcija i proaktivno upravljanje odnosima s kupcima. Važno ga je shvatiti kao sustav jer pomoću njega se stvara pravilnu sliku o tome što raditi s kupcima, kako ih poticati na kupnju i slično. Ukratko to uključuje sve aspekte odnosa i interakcija prema kupcima.

Kotler, Wong, Saunders i Armstrong (2006.) objašnjavaju kako se CRM sastoji od softvera i analitičkih alata koji integriraju informacije o kupcima iz različitih izvora, zatim ih analiziraju te primjenjuju u izgradnji odnosa prema svim kupcima. Poduzeća koriste analizu za ocjenjivanje vrijednosti kupaca i time određuje koje kupce je najbolje ciljati i prema kojim kupcima je najbolje prilagođavati proizvode i usluge.

Muller i Srića (2005.) definiraju CRM kao poslovnu strategiju koja uključuje selekciju i upravljanje odnosima s kupcima s ciljem stvaranje dugoročne vrijednosti za poduzeće. CRM strategija mora biti koordinirana kroz sve odjele poduzeća.

Car (2013.) navodi kako je CRM način ili strategija prikupljanja svih relevantnih podataka o kupcima sa svrhom izgradnje dugoročnih i profitabilnih odnosa s kupcima. Pojam CRM često danas podrazumijeva i tehnologiju kojom se izravno upravlja odnosima, a obuhvaća rješenja za upravljanje marketingom, prodajom i pružanjem usluga.

5.1. Vrste CRM-a

Uvijek je postojala debata između menadžerskog i tehnološkog isticanja. Na temelju toga, Buttle i Maklan (2015.) smatraju da oni sa više menadžerskog isticanja, tvrde kako je CRM disciplinski pristup razvoju i održavanju profitabilnih odnosa s kupcima, a ta tehnologija može ili ne mora imati nikakvu ulogu. Međutim, teško je zamisliti veliku organizaciju koja se bavi milijunima korisnika na više kanala da mogu implementirati CRM bez upotrebe tehnologija informacijskih sustava i dizajniranih poslovnih procesa. Ta rasprava između menadžerskih i tehnoloških škola razriješila se osmišljavanjem CRM-a kao tri glavna oblika, a to su strateški, operativni i analitički.

5.1.1. Strateški CRM

Strateški CRM igra važnu ulogu u oblikovanju odnosa s kupcima. Njegov glavni cilj je fokusirati se na znanje o kupcima te ga konstantno unaprijeđivati kako bi se poboljšale interakcije i zadržali dugoročni odnosi s kupcima.

Na to se nadovezuje, Car (2013.) koji navodi kako je strateški CRM fokusiran na razvoj i izgradnju korporativne kulture orijentirane na korisnike. Kao sami cilj ističe pridobivanje novih korisnika i zadržavanje postojećih izgradnjom vrijednosti boljih od konkurencije. Drugim riječima, ideja ovog CRM-a je da će korisnik biti zadovoljan ako ga poslužuje zadovoljan zaposlenik.

Danyel (2017.) govori kako se strateškim CRM-om ključne informacije o klijentima dijele između poslovnih odjela kao što su prodaja, marketing, tehnička podrška i slično. Povratne informacije od podrške marketinški tim može koristiti za povezivanje s kupcima koji se odnose na određene proizvode. Bez zajedničkog CRM-a to se općenito ne bi dogodilo jer se podaci često ne dijele i mogu se izgubiti, te na kraju time se i oštećuje cjelokupan odnos s kupcima. Cjelokupni cilj je unaprijediti iskustvo kupaca, poboljšati lojalnost i povećati prodaju.

Buttle i Maklan (2015.) smatraju kako strateški CRM potiče na razvoj poslovnih kultura usredotočenih na kupce s ciljem osvajanja i održavanja kupaca. Takve kulture ogledaju se u ponašanju vodećih u poduzeću, dizajnu formalnih sustava te mitovima i pričama koje se stvaraju unutar poduzeća.

Veliki dio poduzeća danas tvrdi kako im je orijentiranost prema kupcima glavna strategija. Međutim, na kraju se uspostavi kako to baš i nije istina. Upravo zbog toga orijentiranost prema kupcima se natječe sa drugim poslovnim orijentacijama. Pa tako, Kotler (2000.) navodi tri dodatne poslovne orijentacije, a to su:

- **Poduzeća orijentirana na proizvod** – takva poduzeća vjeruju kako kupci odabiru proizvode s najboljom kvalitetom. Ovdje se često radi o inovativnim i poduzetničkim poduzećima, koje karakterizira to da se kupčev glas ne čuje prilikom donošenja odluka o marketingu, prodaji i slično. Uprava poduzeća stvara pretpostavku što kupci žele.
- **Poduzeća orijentirana na proizvodnju** – ovakva poduzeća usredotočena su na operativnu izvrsnost. Nastoje kupcima ponuditi najbolju vrijednost, održavati niske troškove poslovanja te razvijati standardizirane ponude i rute na tržištu. Složenost, prilagodba i inovacije vrlo su skupi za ovu vrstu poduzeća. One svoj razvoj fokusiraju na optimizaciju i pojednostavljenje opskrbnog lanca. Ova poduzeća su rijetko prva na tržištu s najboljom ponudom.
- **Poduzeća orijentirana na prodaju** – ovakva poduzeća vjeruju da ako budu ulagali u oglašavanje, prodaju, odnose s javnošću, promociju i slično, da će kupci biti više uvjereni u kupnju njihovog proizvoda. Poduzeća nastoje proizvoditi proizvode s niskim troškovima, zatim ih moraju snažno pomicati za oslobođenje inventara, što znači da ovakva poduzeća primjenjuju pristup “napravi i prodaj”.

Matteson (2013.) smatra kako je uloga strateškog CRM-a poboljšati znanje kupaca te ga iskoristiti u održavanju odnosa i ispunjenju potreba. To je moguće kroz nekoliko koraka:

1. **Pojačavanje predanosti** – što znači da on mora biti prisutan u svim funkcijama kao što su marketing, financije i slično. Također, vrlo je važno imati i korisničku podršku koja zaprima povratne informacije kupaca koje će im pomoći u definiranju strategije.
2. **Izgradnja projektnog tima** – nakon što se utvrde i osiguraju organizacijska struktura i zadaci, važno je razviti strategije te uspostaviti kvalitetan projektni tim. Članovi tog tima su uvijek stručnjaci te sudjeluju u donošenju odluka.
3. **Analiza zahtjeva** – strategija se mora fokusirati na stvarne zahtjeve poslovanja. Uključuje upitnike i ankete s visokom prodajom, financijskim menadžerima i marketingom kako bi se ispravili svi podaci, postigao poslovni cilj te zadovoljile potrebe kupaca.

Kumar i Reinartz (2012.) navode kako strateški CRM proizlazi iz dobrih marketinških principa, te on prepoznaje potrebu uravnoteženja organizacijskih odnosa s interesima kupaca. Cilj strateškog CRM je oblikovanje interakcija između poduzeća i kupaca na način da se maksimizira vrijednost kupca za poduzeće. Uspješan strateški CRM sastoji se od skupa složenih aktivnosti koje čine zajedničku osnovu održivosti. Takav CRM zahtjeva četiri

komponente, a to su orijentacija na upravljanje, integracija organizacijskih procesa, prikupljanje podataka i tehnologije i implementacija postavljene strategije.

Muller i Srića (2005.) ističu kako strateški CRM uključuje sve funkcije koje osiguravaju interakcije s vanjskim subjektima. Točnije, on predstavlja komunikacijski centar prema van i mrežu kontakta poduzeća kroz moguće kanale komunikacije. Znači, putem strateškog CRM-a ostvaruju se kontakti iz kojih se kasnije izvlačene podaci koji su osnova za analitički CRM.

5.1.2. Operativni CRM

Za operativni CRM može se reći kako je to razina na kojoj se obavljaju konkretni zadaci. Drugim riječim, operativni CRM se bavi kreiranjem informacijama koje se kasnije pohranjuju u razne baze podataka. Odnosno zadužen je za svakodnevnu komunikaciju sa kupcima. Osim toga on je poveznica između svih ostalih dijelova u poduzeću koja omogućuje automatizaciju svih procesa i zajedničko djelovanje svih funkcija zajedno.

Na to, Zasso (2016.) dodaje kako operativni CRM pomaže mnogim procesima centriranim prema klijentima, kao što su marketing, prodaja i usluge da se izvode u bilo kojem datom poslu. Vođenje evidencije o korisničkim podacima, praćenje različitih tijekova rada za prodaju i stvaranje potencijalnih kupaca, sve se to može dogoditi unutar operativnog CRM-a. U osnovi, operativni CRM će povezati podatke o kontaktima, povijest narudžbe i sve prijašnje informacije prethodnih komunikacija između kupaca i poduzeća na jednom mjestu.

Car (2013.) govori kako operativni CRM obuhvaća "front office" aplikacije koje podržavaju različite funkcije u poduzeću. Znači radi se o aplikacijama pomoću kojih zaposlenici mogu uvidjeti kupčev profil kod pružanja usluge, koje služe za kreiranje marketinških kampanja, izradu ponuda i upravljanje prodajnim aktivnostima.

Buttle i Maklan (2015.) smatraju kako operativni CRM automatizira poslovne procese usmjerene prema klijentima. Postoje različite softverske aplikacije koje omogućuju automatizaciju i integraciju funkcija kao što su marketing, prodaja i slično. Operacijski CRM sastoji se od tri glavne skupine aplikacija, a to su:


- **Automatizacija marketinga** – odnosi se na primjenu tehnologija u marketinškim procesima. Moduli za upravljanje kampanjom omogućuju marketingu upotrebu podataka vezanih uz klijente, kako bi razvili ciljanu komunikaciju i ponudu. Segmentacija kupaca u svrhu kampanje je nekad moguća i na razini pojedinca, pa je moguće dizajnirati i jedinstvenu komunikaciju.
- **Automatizacija prodajne snage** – ovo je bio izvorni oblik operativnog CRM-a. Primjenjuje se tehnologija za upravljanje prodajnim aktivnostima poduzeća. Prodajni proces se može razgranati na nekoliko stupnjeva. Softveri se mogu konfigurirati tako

da budu modelirani prema prodajnom procesu bilo koje industrije ili organizacije. Odnosno taj softver pomaže poduzećima da automatski prate prilike u prodajnom lancu. Tu još spadaju aplikacije za upravljanje prilikama, kontaktima, ponudom i prijedlozima, konfiguraciju proizvoda i slično.

- **Automatizacija usluga** – obuhvaća primjenu tehnologije u procesima koje obavlja služba za korisnike. Automatizacija usluga pomaže poduzećima da upravljaju servisnim procesima, bilo da se isporučuju putem kontaktnog centra, terenske službe, putem weba i slično, uz visoku razinu učinkovitosti i pouzdanosti. Točnije, softver za automatizaciju omogućuje poduzećima da obrađuju ulazne i izlazne komunikacije preko svih kanala. Tu još spadaju upravljanje slučajevima, upravljanje komunikacijom, upravljanje razinom usluge te čekanje i usmjeravanje.

Muller i Srića (2005.) govore kako je ključni dio operativnog CRM-a integracija s drugim informacijskim sustavima u poduzeću te mogućnost razmjene podataka. Takvim povezivanjem svih sustava dobiva se jača kontrola odnosa s kupcima.

Dycha (2001.) definira operativni CRM kao područja na kojima se javlja izravni kontakt s korisnicima. Takve interakcije koje se događaju nazivaju se dodirne točke. Dodirna točka može biti poziv korisničkoj podršci ili kontakt na temelju vanjskog djelovanja kao što je naprimjer promocija e-mailom. Operativni CRM omogućuje i pojednostavljuje komunikaciju s korisnicima i od njih, ali to ne znači nužno optimiziranje usluge.



Slika 8. Razine operativnog CRM-a (Izvor: Dycha,2001.)

Operativni CRM se općenito odnosi na usluge koje omogućuju organizaciji brigu o svojim klijentima. On kao takav pruža podršku za različite poslovne procese. Kontaktni centri, sustavi prikupljanja podataka i web stranice su samo neki primjeri operativnog CRM-a. Ako

poduzeća imaju visoki promet kupaca ili čak možda visoke troškove usluga, rješenja operativnog CRM-a mogu im pomoći u rješavanju sličnih problema. Osim toga visoka stručnost CRM-a omogućuje poduzećima pristup informacijama o kupcima i daje jasne uvide u njihove potrebe. (straightmarketing,bez dat.)

Danyel (2017.) navodi kako je glavna uloga operativnog CRM stvaranje potencijalnih kupaca, a zatim ih pretvoriti u kontakte unutar CRM-a. Što se tiče prodaje, omogućuje učinkovitije upravljanje postojećim kupcima, stjecanje novih te učinkovitu organizaciju informacija. Njegovi razni moduli uključuju upravljanje kontaktima i vodstvom, ali i predviđanje prodaje.

Matteson (2013.) smatra kako se operativni CRM usredotočuje na tri glavna područja, a to su informatizacija, povećanja i poboljšavanje usluga. Ta područja temelj su pružanja korisničke podrške.

5.1.3. Analitički CRM

Analitički CRM se sastoji od detaljnih analiza, što ga svrstava u najzahtjevniju i najskuplju komponentu cijelog CRM sustava. Analitički CRM nije u izravnom kontaktu s kupcima, nego on obrađuje velike količine podataka koje proizlaze iz operativnog i strateškog CRM-a. Cijelo djelovanje analitičkog CRM-a temelji se na obradi i skladištenju podataka.

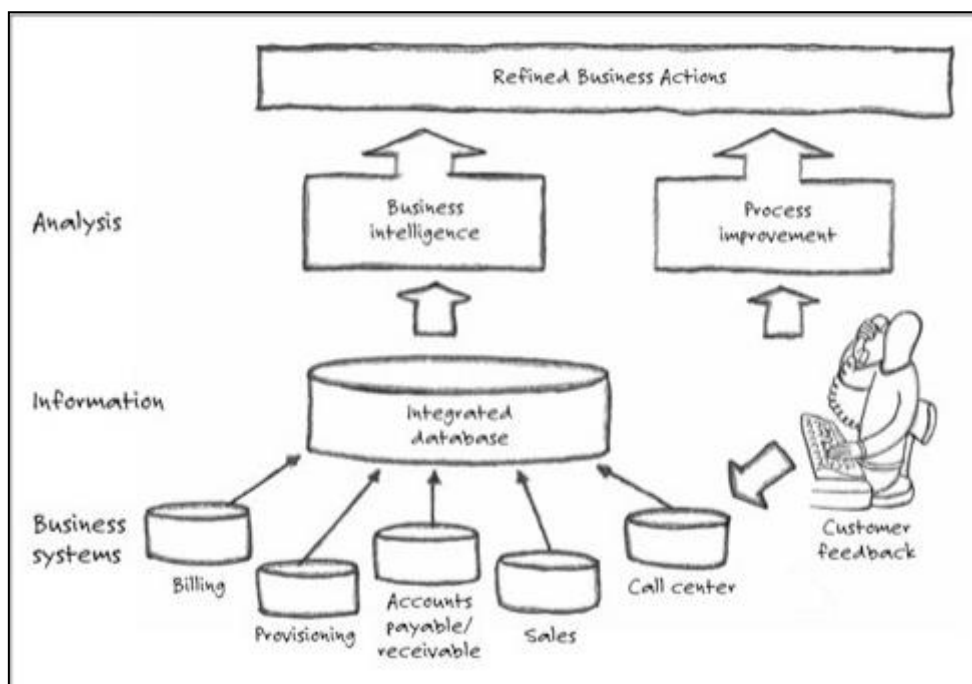
Na to se nadovezuje, Car (2013.) koji govori da se analitički CRM odnosi na prikupljanje, sistematiziranje i obradu podataka te njihovu preobrazbu u informacije važne za upravljanje odnosima s kupcima. Osim toga analitički CRM je zadužen za skladištenje podataka te njihovo prosljeđivanje drugim dijelovima sustava.

Caufield (2001) navodi kako analitički CRM uključuje implementaciju naprednih alata za upravljanje i analizu podatak koji omogućuju napredno upravljanje odnosima s kupcima. Odnosno to je analiza podataka koje je pripremio operativni CRM s ciljem upravljanja poslovnim učinkom.

Buttle i Maklan (2015.) smatraju kako se analitički CRM bavi hvatanjem, pohranjivanjem, ekstrakcijom, integracijom, obradom, tumačenjem, distribucijom, korištenjem i izvještavanjem podataka koji su povezani s kupcima s ciljem poboljšanja vrijednosti kupaca i poduzeća. Analitički CRM može navesti poduzeće da shvati kako se prodajni pristup razlikuje prema određenim grupama kupaca. S gledišta kupca, analitički CRM može isporučiti pravodobno i prilagođeno rješenje njihovog problema, što na kraju povećava njihovo zadovoljstvo. Dok s gledišta poduzeća on nudi mogućnosti za snažnije programe zadržavanje kupaca.

Dycha (2001.) definira analitički CRM kao "back office" koji uključuje razumijevanje korisničkih aktivnosti koje su se dogodile u "front office-u". On kao takav zahtjeva tehnologiju

za prikupljanje i obradu podataka radi olakšavanja analize i nove poslovne procese za povećanje lojalnosti i profitabilnosti.



Slika 9. Analitički CRM (Izvor: Dycha,2001.)

Joenn (2011.) govori o tome kako analitički CRM pruža informacije koje podupiru odluku koja se mora poduzeti u vezi s nekim aspektom marketinga, podrške, odnosa s kupcima ili ljudima koji su odgovorni za obavljanje tih funkcija unutar poduzeća. Odnosno drugi riječim, analitički CRM pretvara podatke u znanje.

Glavna funkcija analitičkog CRM-a je analiza podataka, pa stoga, Danyel (2017.) navodi da promatrajući i analizirajući podatke o kupcima menadžment može puno bolje steći uvid u trenutni poslovni status. Odluke se donosne brže i učinkovitije, te osim toga on omogućuje praćenje kampanja. Informacije se prikupljaju iz različitih kanala, a zatim se analiziraju na strukturiran način.

Muller i Srića (2005.) ističu kako je uloga analitičkog CRM-a prikupljanje, procesiranje i izvještavanje podataka o kupcima te da on posjeduje mogućnost prihvaćanja podataka iz velikog broja različitih izvora.

Matteson (2013.) navodi kako ovaj tip CRM-a ima za cilj prema organizaciji povećati razvoj, poduprijeti i unaprijediti donošenje odluka. Osim toga on uspostavlja snažne obrasce i prognoze podataka o kupcima koji su prikupljeni iz različitih dijelova operativnog CRM-a. Ostale njegove značajke su postavljanje i provedba ishoda, analiziranje, utvrđivanje i razvoj pravila i metoda za optimizaciju i dobivanje važnih informacija o kupcima iz različitih izvora.

Analitički CRM upotrebljava se za obrađivanje analize korisničkih podataka za mnoštvo različitih svrha. Općenito se koristi za dizajn i izvršavanje marketinških kampanja koje optimiziraju učinkovitost marketinga. On uzima u obzir i odlučivanje o proizvodu i uslugama, kao i cijenu i razvoj novih proizvoda. (straightmarketing,bez dat.)

5.2. Implementacija CRM-a

Proces implementacije je vrlo zahtjevan te mu je cilj uskladiti poslovne ciljeve i mogućnosti integracije CRM sustava s postojećim sustavom u poduzeću. Upravo zbog toga, Muller i Srića (2005.) naglašavaju važnost preispitivanja trenutnog stanja u kojem se poduzeće nalazi, prije samog početka implementacije sustava i utvrđivanja adekvatne točke početka nove implementacije za ostvarivanje maksimalne koristi iz novog projekta. Takvu implementaciju treba voditi tim koji snosi punu odgovornost.

Na početku implementacije potrebno je definirati cilj, a potom tu implementaciju razbiti u nekoliko odvojenih projekata. Nakon toga određuju se prioritete pojedinih projekata i redoslijed implementacije te mjera uspješnosti. Sami proces uključuje planiranje, određivanje arhitekture i dizajna, tehnologije koja će se koristiti, isporuku gotovog sustava te mjerenje rezultata. Što se tiče mjera uspješnosti ona trebaju biti jasna, mjerljiva i komparabilna s prijašnjim stanjem i postavljenim ciljevima. (Muller i Srića,2005.)

Uz jasno definirana mjera lakše je mjeriti isplativost investicije u CRM te je isto moguće doći do zaključaka koje inicijative funkcioniraju bolje, a koje lošije u određenom okruženju poduzeća. Još jedan važan dio u implementaciji je trening zaposlenika koji koriste CRM sustav jer u konačnici uspješnost najviše ovisi o tome koliko će ga korisnici koristiti i koliko će pomagati u izvršavanju njihovih zadataka. Vrijeme treninga ovisi o broju korisnika i dostupnim prostorima za njihovo održavanje. (Muller i Srića,2005.)

Brodarić (2010.) navodi kako CRM sustav zahtijeva analizu, dizajn i implementaciju poslovnih procesa te uspostavljanje i učvršćivanje veza između tih procesa unutar poduzeća. Prije implementacije važno je da poduzeće uzme u obzir određene faktore, a to su kvalitetan podatkovni model, fleksibilna aplikacijska razina, automatizacija procesa i intuitivno korisničko sučelje.

Poslovni ciljevi i strategija poduzeća moraju biti jasno definirani i iznešeni. Pri izražavanju tih jasno definiranih ciljeva potrebno je razmotriti dugoročne potrebe upravljanja odnosima s kupcima te započeti analizu i dizajn. CRM rješava problem kako uz pomoć strategije ostvariti bolje odnose s kupcima i bolju kvalitetu usluga. To se ne prikazuje samo u tehničkom smislu

nego i u smislu kvalitetnog upravljanja korisničkim zahtjevima i upravljanjem uslugama korisnika tako da postignemo efikasniju kontrolu: (Brodarić,2010,str.103.)

- Upravljanja korisničkim uslugama
- Upravljanja korisničkim zahtjevima
- Upravljanja korisničkom podrškom – kontaktni centar
- Upravljanje isporukom i održavanja korisničkih usluga
- Upravljanja prodajom i marketingom
- Upravljanje korporativnim ciljevima
- Upravljanja učincima, ključnim pokazateljima poslovanja
- Upravljanja prihodima

Fazu analize i dizajna predstavlja dokument koji se izrađuje na temelju dokumentacije koja prati pojedine podfaze u poslovnom, operativnom i mrežnom dijelu. Svrha tog dokumenta je definirati funkcionalne i tehničke zahtjeve za pojedine komponente i ukupni sustav da bi se na kraju na temelju tog dokumenta prikazao konačni dizaj koji će se koristiti. Analiza i dizajn služe kao podloga za fazu testiranja i edukacije. Izbor CRM tehnologije dolazi nakon analize postojećeg stanja, pri dizajnu CRM rješenja. (Brodarić,2010.)

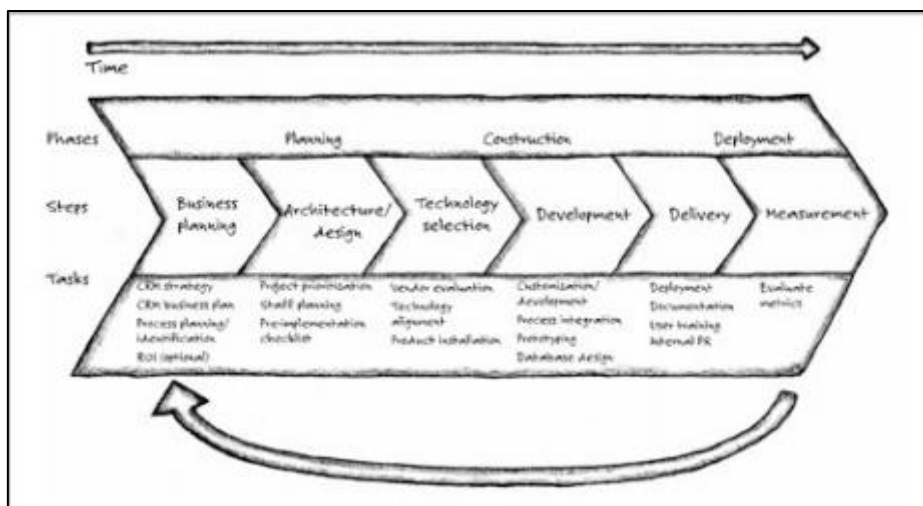
Uvođenje CRM-a provodi se kroz faze te se u modulima implementiraju pojedine specifičnosti i funkcionalnosti. CRM ima svoje potrebe koje je potrebno integrirati sa ostalim sustavima unutar poduzeća, pa se na temelju toga definiraju određena područja funkcionalnosti, a to su: (Brodarić,2010.)

- **Bilježenje komunikacije i kontakata** – evidentiraju se aktivnosti korisnika, njihovu zahtjevi, problemi, komentari i slično.
- **Opis korisnika** – odnosi se na sve podatke koji su prikupljeni tijekom korisničkog životnog ciklusa.
- **Prodajni proces** – evidencija svih sastanaka, ponuda, upita, potencijalnih kupaca. Tu još spada i analitka prodajne uspješnosti te sve popratne aktivnosti prodaje.
- **Procesi isporuke, održavanja i tehnička podrška usluge** – definiranje tijeka procesa kroz više odjela. Olakšava se pristup za vanjske partnere te da pojedine interakcije obavljaju s vanjskim sustavima preko web servisa.
- **Korisnička podrška** – pregled povijesti rada s korisnikom, mogućnost formiranja točnijeg pristupa komuniciranja u budućnosti.
- **Zadavanje i praćenje zadataka** – odnosi se na definiranje zadataka kojima se rješavaju određeni problema.

- **Baza znanja** – baza informacija koja pomaže u rješavanju problema, donošenju odluka, davanju odgovora na pitanja kupaca i slično.
- **Izveštaji i statistika** – Mogućnost kreiranja izvještaja kroz posebne module koji su dio CRM sustava.
- **Integracija** – važno da CRM sustav ima mogućnost povezivanja sa ostalim sustavima u poduzeću.
- **Upravljanje promjenama** – treba odrediti procedure koje će pratiti kada se događaju određene promjene u sustavu. To su najčešće procesi upravljanja incidentima.

Dycha (2001.) smatra kako se implementacijski pristupi mogu razlikovati prema životnom ciklusu poduzeća, stručnosti zaposlenih te informatičkim standardima. Samu implementaciju moguće je prikazati preko mape koja se sastoji od šest koraka, a to su:

1. **Poslovno planiranje** – odnosi se na definiranje općih ciljeva CRM-a bilo da su oni na razini odjela ili cijelog poduzeća. Na razini cijelog poduzeća CRM poslovno planiranje može uključivati dokumentaciju korporativne strategije te odgovarajućih programa unutar nje. Tu još spadaju zadaci kao što su izrada poslovnog plana te identifikacija procesa.
2. **Arhitektura i dizajn** – ovaj korak se odnosi na prepoznavanje procesa koje će CRM podržati. Uključuje prepoznavanje specifičnih funkcija koje će morati biti provedene s ciljem što boljeg shvaćanja utjecaja CRM-a na organizaciju i tehnologije. Uključuje još zadatke kao što u planiranje zaposlenih te stvaranje popisa za provjeru.
3. **Selekcija tehnologije** – odnosi se na usklađivanje CRM proizvoda sa postojećom IT infrastrukturom.
4. **Razvoj** – odnosi se na izgradnju i prilagodbu CRM proizvoda, koristeći njegove specifične značajke, odnosno integraciju poslovnih procesa s odabranim proizvodom. Tu još spadaju zadaci kao što su prilagođavanje, dizajn baze podataka i slično.
5. **Isporuka** – odnosi se na iskorištavanje korporacijske IT infrastrukture za slanje dobivenog CRM softvera poslovnim korisnicima kojim je potrebno. U ovoj fazi još su zadaci poput razvoja, dokumentacije i obuka korisnika.
6. **Mjerenje** – odnosi se na procjenjivanje mjernih podataka, naprimjer kako procijeniti da li je uspjeh CRM utjecao na rješavanje postojećih problema i u kolikoj mjeri.



Slika 10. Koraci CRM implementacije (Izvor: Dycha,2001.)

Buttle i Maklan (2015.) definiraju pet osnovnih faza CRM implementacije, a to su:

1. **Razvijanje CRM strategije** – to je plan visokog stupnja djelovanja koji usklađuje ljude, procese i tehnologiju za ostvaranje ciljeva vezanih uz kupce. Sastoji se od podfaza kao što su: analiza stanja, CRM obrazovanje, razvoj CRM vizije, postavljanje prioriteta, utvrđivanje ciljeva, identifikacija neprevidenih slučajeva, resursa i slično.
2. **Izrada temelja CRM projekta** – u ovoj fazi uspostavlja se struktura upravljanja, identificiraju potrebe upravljanja promjenama, zatim potrebe upravljanja projektom, identificiraju se kritični faktori uspjeha te razvija plan upravljanja rizicima.
3. **Specifikacija potreba i selekcija partnera** – sastoji se od procesnog inženjerstva, pregleda podataka i analize jaza, postavljanja tehnološke specifikacije i istraživanja alternativnih rješenja, prepoznavanja identifikacijske potrebe tehnologije, procjene i odabira partnera i slično.
4. **Provedba projekta** – odnosi se na pročišćavanje projektnog plana, identificiranje potreba za prilagodbom tehnologije, donošenje prototipa dizajna, testiranje projekta, provođenje izmjena i slično.
5. **Ocjena projekta** – uključuje procjenu učinka projekta. U ovoj fazi mogu se mjeriti dvije skupine varijabli, a to su rezultati projekta i ostvareni rezultati poslovanja. Rezultati projekta usmjereni su na to da li je projekt dostavljen na vrijeme i da li je unutar postavljenog budžeta. Procjena rezultata poslovanja zahtijeva da se vratimo na ciljeve projekta, definiciju uspjeha i zapitamo da li su postignuti željeni rezultati.

Kumar i Reinartz (2012.) ističu kako implementacija CRM-a zahtijeva određene procese i aktivnosti kako je i prikazano u implementacijskoj matrici. Ta matrica sadrži veliki obujam potencijalnih aktivnosti i strukturirana je na dvije ključne dimenzije, a to su:

1. **Dimenzija kupaca** – odnosi se na promjene faza u odnosima kupaca s poduzećem, kao što su stjecanje kupaca, rast i zadržavanje te napuštanje.
2. **Dimenzija upravljanja** – aktivnosti i procesi koji čine analitički i operativni CRM. Analitički CRM nam služi za razumijevanje kupčevih potreba i očekivanja, dok nam operativni CRM pomaže u izvođenju i upravljanju interakcija.

		Customer Dimension		
		Acquisition Stage	Growth and Retention Stage	Decline and Exit Stage
Management Dimension	Analytical CRM			
	Operational CRM			

Slika 11. CRM implementacijska matrica (Izvor: Kumar,Reinartz,2012.)

5.3.Prednosti i nedostaci CRM-a

Caufield (2001.) navodi kako CRM osim kultiviranja lojalnosti kupaca koji pokazuju profitabilni profil kakav tvrtka želi, još donosi i druge prednosti, a to su:

- Poboljšano i detaljno razumijevanje kupaca
- Poboljšana komunikacija s kupcima
- Povećana sposobnost prilagođavanja globalizaciji i deregulaciji
- Povećana sposobnost kontrole korisnika
- Bolja kontrola troškova kojisu povezani sa stjecanjem i zadržavanjem kupaca
- Održavanje konkurentne diferencijacije

Dobre strane CRM-a mogu se širiti izvan poslovanja poduzeća i samih odnosa s kupcima. O čemu govori i Taylor (2014.) koji smatra da idealan CRM sustav treba pomoći poslovanju poboljšati odnose s postojećim kupcima, pronaći nove kupce te osvojiti bivše kupce. Osim toga definira još nekoliko prednosti, a to su:

- **Poboljšana služba za korisnike** – odnosi se na mogućnost davanja osobnog dodira u odnose s kupcima. Odnosno, moguće je tretirati svakog kupca pojedinačno, a ne kao grupu. Ovaj sustav omogućuje svakom zaposleniku razumijevanje specifičnih potreba svakog kupca.
- **Olakšano otkrivanje novih kupaca** – CRM sustav koristan je u identificiranju potencijalnih kupaca i to na način da se prate profili postojećih kupaca i na temelju njih se ciljaju novi kupci od kojih se očekuje najveća stopa povrata.

- **Povećanje prihoda od kupaca** – CRM podaci osiguravaju učinkovitu koordinaciju marketinških kampanja. Moguće je filtrirati podatke i osigurati da promocije ne ciljaju one koji su već kupili određene proizvode. Poduzeća također mogu koristiti podatke za uvođenje programa lojalnosti koji osiguravaju veći omjer zadržavanja kupaca.
- **Brže zatvaranje poslova od strane prodajnog tima** – odnosi se na olakšavanje bržih i učinkovitijih odgovora na kupce i informacije kupaca. Kupci se više uvjeravaju da svoje upite pretvore u kupnju kada im se i na iste brzo odazove.
- **Poboljšani cross-selling i up-selling** – cross-selling uključuje ponudu komplementarnih proizvoda na temelju prethodnih kupnji, dok se up-selling odnosi na ponudu premium proizvoda kupcima u istoj kategoriji.
- **Pojednostavljeni prodajni i marketinški procesi** – CRM olakšava razvoj boljih i učinkovitijih komunikacijskih kanala. Tehnološke integracije poput web stranica i interaktivnih sustava glasovnog odgovora mogu olakšati posao predstavnicima prodaje kao i cijelom poduzeću. Takve strategije osiguravaju odgovarajuću dostavu komunikacije, brze odgovore na upite i povratne informacije od kupaca.
- **Učinkovitiji pozivni centri** – ciljanje kupaca uz pomoć CRM softvera je lakše jer zaposlenici imaju pristup povijesti narudžbi i detaljima kupaca. Pomaže im kako se nositi sa svim kupcima ovisno o njihovim snimljenim arhivama. Podacima u softveru može se pristupiti odmah iz bilo koje točke unutar poduzeća.
- **Povećanje lojalnost** – u većini slučajeva lojalni kupci postaju preporuke poslovanja te ponuđenih proizvoda i usluga. Na temelju toga, poduzeće može promovirati proizvode i usluge na temelju iskaza kupaca.
- **Učinkovitija interna komunikacija** – različiti odjeli unutar poduzeća mogu dijeliti informacije na daljinu što pridonosi jačanju timskog rada.
- **Optimiziran marketing** – CRM pomaže u prepoznavanju točnog vremena za prodaju proizvoda kupcima.

Thakral (2017.) navodi tri glavna nedostatka korištenja CRM-a, a to su prijelaz iz ručnih na automatske procese, psihologija praćenja i kratkoročno usporavanje procesa.

Shah (2016.) definira četiri nedostatka koji se pojavljuju prilikom korištenja CRM-a:

1. **Održavanje** – instaliranje može biti jednostavno, ali podrška i održavanje definitivno nisu. Pravilno održavanje zahtjeva veliku tehničku stručnost. Također su potrebni i konzultati koji će pomoći u odabiru i prilagođavanju pravog CRM sustava koji najbolje odgovara poslovanju.

2. **Nema središnjeg sustava podrške** – ne postoji jedno mjesto kojem se može pristupiti s našim problemima. Sva rješenja i podrška tih problema nalaze se na različitim forumima. Rješenja na forumima nisu uvijek točna, te će se još uz to potrošiti i puno vremena čekajući odgovore.
3. **Ograničena funkcionalnost** – funkcija CRM je ponekad ograničena i dolazi sa nedostacima. S dodatnim ulaganjem mogu se dodati nove značajke i time proširiti ograničenje.
4. **Nije posve besplatno** – postoje mnogi skriveni troškovi kao što su troškovi razvojih programera, održavanja, infrastrukture i slično.

6.Korištenje velikih podataka u CRM-u

Veliki podaci i CRM su povezani na način da CRM izvlači vrijednost iz velikih podataka. Odnosno drugim riječim, vrijednost se izvlači iz velikih podataka i zatim se nastoji pretvoriti u pametne i korisne podatke kroz integraciju sa CRM sustavom. Kombinacija ova dva sustava može znatno utjecati na poboljšanje poslovanja, ali može pomoći i zaposlenicima da shvate ključne stvari prije kontaktiranja kupaca. Previše podataka može stvoriti problem pretrpanosti, stoga je ključno istaknuti prikupljanje samo najpotrebnijih.

Franklin (2014.) govori o tome kako big data može znatno promijeniti način na koji poduzeće upravlja odnosima s kupcima, nudeći moćne alate pomoću kojih mogu identificirati prodajne prilike i analizirati odgovore kupaca. Poduzeće preko velikih podataka i CRM analitike pronalazi udruge i prepoznaje trendovi koji mu omogućuju da oblikuje korisnička iskustva za povećanje angažmana i veće zarade.

Meyers (2017.) navodi kako su mogućnost velikih podataka velike, ali da bi mogli pravilno iskoristiti te podatke i steći pravi uvid u njih, potrebno je imati prave alate za njihovu obradu. Pa tako ako, poduzeće želi iskoristiti prednosti velikih podataka, prvo trebaju ulagati i razviti dobar softver za upravljanje odnosima s kupcima. CRM može pratiti podatke koje kupci ostavljaju na raznim mrežama te ih prezentirati na pravi način.

Big data CRM je novi pojam koji se nedavno počeo koristiti te on označava integraciju velikih podataka u CRM procese poduzeća s ciljem poboljšanja službe za korisnike, izračunavanje povratnih ulaganja te predviđanje ponašanja kupaca. Glavni cilj je kombinirati interne CRM podatke s podacima kupaca koji se nalaze izvan postojećeg sustava poduzeća. Takva kombinacija velikih podataka i CRM podataka može poboljšati analizu kupaca. Poduzeća koja koriste velike podatke u suradnji sa CRM-om imaju sustave pomoću kojih obrađuju podatke u stvarnom vremenu. (Rouse,2015.)

Big data CRM je integracija velikih podataka u CRM sustav poduzeća. Uz pomoć njega poduzeće može analizirati i predvidjeti ponašanje kupaca u korist vlastite poslovne strategije. Pronalaženjem trendova i obrazaca u podacima, poduzeća mogu osmisлити pravu prodajnu strategiju i bolje iskoristiti raspoložive prodajne mogućnosti. (agiratech,bez dat.)

Franklin (2014.) definira pet glavnih razloga integracije big data u CRM, a to su:

1. **Poboljšana analiza kupaca** – analiza svih dodirnih točaka kupaca, omogućuje CRM-u i velikim podacima da segmentiraju kupce na temelju akcije koju je kupac poduzeo. Različiti trendovi koji se izvlače iz velikih podataka mogu koristiti za predviđanje potreba, usmjeravanje razvoja novih proizvoda i slično.

2. **Bolja slika procesa usmjerenih prema kupcima** – veliki podaci pružaju marketinšku i prodajnu analizu kupaca. Poduzeće može koristiti velike podatke za predviđanje povrata ulaganja te ih koristiti za potporu novih ulaganja u CRM.
3. **Bolje donošenje odluka** – kada se jasno procjene vrijednosti i nedostaci poslova koji se obavljaju, poduzeće može napraviti ispravke na temelju kojih će donositi bolje odluke u vremenima koja dolaze.
4. **Predviđanje modeliranja** – uz pomoć velikih podataka poduzeća mogu predvidjeti kako će kupci reagirati u budućnosti.
5. **Benchmarking** – omogućuje poduzećima da prate svoje vitalne pokazatelje, napredak i izvedbu vezanu uz strategiju i konkurente. Osim toga provode se usporedne analize različitih čimbenika kao što su zadovoljstvo, zadržavanje prihoda i slično.

6.1. Rudarenje podataka

U današnjem poslovanju informacije su postale vrlo vrijedan resurs. Rudarenje je izvlačenje tih informacija iz velikih skupova podataka ili baza podataka. Ponekad informacije nisu dovoljne, već je potrebno imati i znanja kako najbolje iskoristiti te informacije u korist poslovanja. Rudarenje je pristuno u raznim sektorima, ali ponajviše u marketingu gdje se koristi s ciljem identificiranja kupaca, poboljšanja prodaje, lojalnosti i slično.

Na to, Berry i Linoff (2004.) govore kako je glavni cilj rudarenja podataka omogućiti poduzeću poboljšanje marketinga, prodaje i operacije korisničke podrške kroz bolje razumijevanje kupaca. Rudarenje podacima dolazi u dva oblika, a to su usmjereno i ne usmjereno rudarenje. Usmjereno rudarenje nastoji objasniti ili kategorizirati određeno ciljno polje kao što su prihodi ili odgovor kupca, dok ne usmjereno rudarenje pokušava pronaći sličnosti među skupinama zapisa bez određenog ciljnog polja.

Caufield (2001.) navodi kako rudarenje podataka uključuje softverske alate koji omogućuju korisnicima da prolaze kroz velike količine podataka kako bi otkrili sadržaje podataka vezane uz odnose te izgradili model za previđanje ponašanja kupaca.

Tsiptsis i Chorianopoulos (2009.) smatraju kako rudarenje podataka ima za cilj izvući znanje i uvid kroz analizu velikih količina podataka koristeći sofisticirane tehnike modeliranja. Podaci koji se trebaju analizirati mogu se nalaziti u dobro organiziranim skladištima ili se mogu izdvojiti iz različitih nestrukturiranih izvora podataka. Modeli za rudarenje podataka sastoje se od različitih pravila, jednadžbi ili složenih funkcije prijenosa koji se mogu koristiti za prepoznavanje podataka i predviđanje ponašanja.

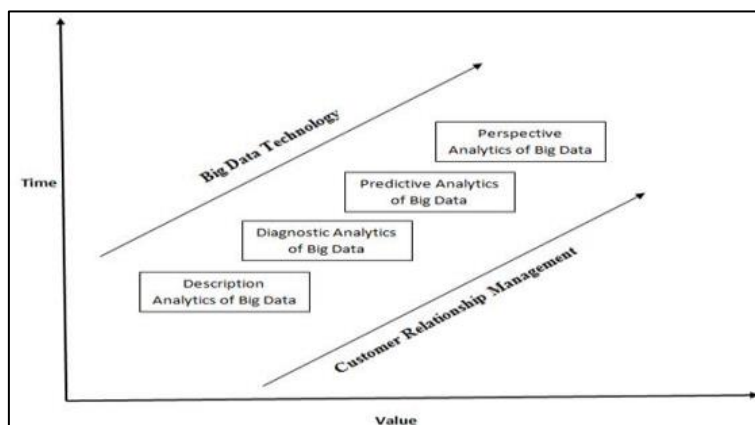
Što se tiče CRM-a, rudarenje podacima može pružiti uvid u kupce što je ključno za uspostavu učinkovite CRM strategije. Kroz analizu podataka se može doći do personaliziranih interakcija s kupcima, povećanog zadovoljstva i profitabilnih odnosa s kupcima. Rudarenje podacima također može podržati optimizirano upravljanje kupcima tijekom svih faza njihovog životnog ciklusa. (Tsiptsis,Chorianopoulos,2009.)

Tsiptsis i Chorianopoulos (2009.) navode tri glavna područja CRM-a u kojima rudarenje podataka ima utjecaja, a to su:

1. **Segmentacija korisnika** – rudarenje može stvoriti segmente ponašanja koji su vođeni podacima. Različiti algoritmi mogu analizirati podatke ponašanja, prepoznati grupacije korisnika i predložiti rješenje utemeljeno na promatranim podacima. Kada su modeli podataka ispravno izgrađeni, oni mogu otkriti skupine s različitim profilima i karakteristikama te dovesti do bogatih shema segmentacije s visokom poslovnom vrijednošću.
2. **Izravne marketinške kampanje** – modeli rudarenja i klasifikacije mogu podržati razvoj ciljane marketinške kampanje. Takvi modeli analiziraju karakteristike kupaca i prepoznaju njihove profile. Pravilno izgrađeni modeli mogu identificirati prave korisnike za kontakt i te povećati gustoću popisa kampanje sa više ciljanih kupaca.
3. **Tržišna košarica i analiza sekvenci** – modeli rudarenja i asocijacije mogu se koristiti kako bi se identificirali povezani proizvodi koji su obično kupljeni zajedno. Takvi modeli mogu se koristiti za analizu tržišnih košarica i za otkrivanje paketa proizvoda koji se mogu prodati zajedno. Modeli sekvenci uzimaju u obzir redoslijed kupnje i identificiraju događaje.

Koraci velikih podataka u CRM-u

Yadav,Monika,Kumar i Garima (2015.) jasno slikom definiraju kako veliki podaci imaju niz koraka sa uspješnim CRM aktivnostima.



Slika 12. Veliki podaci u CRM-u (Izvor: Yadav i sur.,2015.)

Prvi korak je opisna analitika velikih podataka. U opisnoj analitici nalazi se kompletni skup podataka dostupan u obliku opisa. To će pomoći poduzeću u poboljšanju odnosa s kupcima. Sljedeći korak je dijagnostička analitika u kojem se koristi podatkovna tehnologija kao što su Hadoop, Hbase i R studio. Treći korak odnosi se na prediktivnu analizu. Prediktivna analiza pruža prediktivno ponašanje koje se koristi u analitici velikih podataka. To je područje koje se razvija uz pomoć tehnologije baze podataka i alata velikih podataka. Predviđanje znači gledati naprijed s nizom naprednih tehnologija koje se temelje na stvarnom vremenu. Naposljetku konačni korak je perspektivna analitika, koja se temelji na analizi velikih podataka. Kombinacija navedenih koraka znatno će poboljšati vrijednost CRM-a. (Yadav i sur.,2015.)

6.2. Skladištenje podataka

Baze podataka su danas zbog svojih mogućnosti pohrane podataka i efikasnog korištenja postale popularne. Pravilno napravljena baza pomaže korisnicima da dođu do potrebnih podataka. Što bi značilo da je baza podataka samim time u isto vrijeme neka vrsta skladišta koja sadrži starije, ali i novo integrirane podatke iz kojih se generiraju različite analize. Na to se nadovezuje, Todman (2000.) koji definira kako se skladište sastoji od četiri glavne značajke, a to su:

1. **Predmetna orijentacija** – podaci su organizirani oko određenog predmeta umjesto aplikacija.
2. **Nepromjenjivost** – znači da podaci, koji su jednom stavljani u skladište, nisu obično podložni promjenama. Svatko tko koristi bazu podataka ima povjerenje da će upit uvijek proizvesti isti rezultat bez obzira na to koliko se često izvodi.
3. **Integriranost** – podaci moraju biti dosljedni. Prije nego što se dopusti ulazak podacima u skladište, oni moraju biti integrirani.
4. **Vremenska varijanta** – odnosi se na bilježenje povijesnih podataka.

Wahl (2005.) navodi kako je skladište podataka integrirana zbirka svih podataka o transakcijama koje postoje unutar poduzeća te se koriste za konsolidaciju i analizu svakodnevnih poslovnih transakcija.

Skladišta podataka u sebi sadrže veliku količinu operativnih, povijesnih i ostalih podataka povezanih s kupcima. Odnosno, Buttle i Maklan (2015.) ističu kako su to spremišta onih podataka koji su uvezeni iz drugih baza podataka koji naposljetku pomažu analitičarima implementirati različite statističke procese pomoću kojih stvaraju smisao od tih podataka.

CRM skladište može ponuditi četiri besprijeckorno integrirana, ali samostalna podatkovna područja koje maksimiziraju povrat od inicijative usmjerene prema klijentima. Kada su ta četiri dijela razvijeni zajedno predstavljaju jedan izvor podataka o klijentima s ciljem dobivanja potpunog izvještaja i analize. Ta četiri dijela odnose se na: (Oracle, bez dat.)

1. **Kupce** – pruža uvid u cjelokupni životni ciklus kroz poslovne procese i tržišne segmente.
2. **Marketing** – bilježi informacije o tradicionalnim i online marketinškim aktivnostima, uključujući profile ispitanika, broj klikova i generiranih potencijalnih klijenata, vodeće kvalifikacijske mehanizme te povrat ulaganja u kampanju kako bi se analizirala učinkovitost marketinških aktivnosti.
3. **Prodaju** – pruža vidljivost u status prodajnog lanca, analizu popusta, prodajni ciklus vremena, analizu padova i slično.
4. **Usluge** – bilježi informacije o svim aktivnostima kontakt centra, uključujući pozive, slučajeve, chatove, e-poštu, omogućujući analiziranje učinkovitosti svih navedenih aktivnosti.

Postoji niz koraka i procesa u izgradnji skladišta podataka. Prvo je važno utvrditi gdje se trenutno nalaze relevantni podaci. Drugo, podaci moraju biti izvađeni iz tih sustava u kojima su trenutno smješteni. Podaci se zatim moraju pretvoriti u standardizirani format, jer su najčešće možda pohranjeni u različitim oblicima. Nakon pretvorbe, podaci se trebaju prenijeti u skladište. Osim toga važno je stalno osvježavati podatke ovisno o brzini promjene u poslovanju i okolini. (Buttle i Maklan, 2015.)

Khan, Ehsan, Mirza i Sarwar (2012.) navode kako CRM funkcionira kroz prikupljanje podataka o klijentima preko svake aktivnosti kupca i preko svake obavljene transakcije. Takvi podaci se analiziraju kako bi se postigla kvaliteta u poslovnim procesima.

Upravo ovdje skladište podataka ima važnu ulogu kao spremište svih operativnih i transakcijskih podataka, podataka o interakciji, korisničkih profila, podataka o ponašanju i slično. Obrada informacija o kupcima može se voditi na dva načina od kojih je prvi sustav obrade transakcija (TPS) temeljen na korištenju baze podataka, a drugi sustav za podršku odlučivanja koji koristi skladište podataka (DSS). (Khan i sur., 2012.)

Tablica 1. Razlika TPS i DSS sustava obrade (Izvor: vlastita izrada prema Khan i sur.,2012)

	Sustav obrade transakcija (TPS)	Sustav podrške odlučivanja (DSS)
Korisnici	Front-line zaposlenici	Menadžment
Svrha	Potpora svakodnevnim operacijama	Potpora strateškom odlučivanju
Podaci	Neobrađeni podaci	Filtrirani i transformirani podaci
Izvor podataka	Interni	Interni i eksterni
Vremenski horizont	Trenutni podaci	Povijesni podaci
Razina detalja	Samo detaljni podaci	Detaljni i sažeti podaci
Struktura podataka	3NF	Denormalizirane tablice
Cilj dizajna	Maksimalna učinkovitost ažuriranja	Maksimalna učinkovitost upita

6.3.Razvoj i upravljanje bazama podataka povezanim s kupcima

Povijest baze podataka kreće od pismenog pohranjivanja, pohranjivanja na računalu te do modernih baza podataka koje se sastoje od raznih aplikacija koje omogućuju lakše analiziranje i pohranu veće količine podataka. Baze podataka danas su postale jedan od važnijih elemenata svakodnevnog poslovanja bilo da se radi o evidenciji proizvoda na skladištu, evidenciji kupca koji dolaze u prodavaonice, praćenju građana, korištenju interneta i slično.

Za bazu podataka kao element poslovanja može se reći da je to skup logički povezanih podataka koji se najčešće koristi kao model za prikupljanje, pohranjivanje i organiziranje podataka. Na to, Maleković i Rabuzin (2016.) smatraju kako baza podataka kao kolekcija podataka, ograničenja i operacija reprezentira neke aspekte realnog svijeta.

Praćenje kupaca pomoću baze podataka povezano je sa CRM sustavom. Prema tome uspješnost CRM sustava ovisi o načinu na koji dolazimo do podataka, načinu na koji ih pohranjujemo i analiziramo te na samom kraju i koristimo. Uz to, Buttle i Maklan (2015.) navode kako je važno razlikovati podatke za i o kupcima, podaci koji su za kupca obično se

pohranjuju u baze znanja koja se može pretraživati i dostupne su kupcima preko različitih portala. Dok podaci o kupcima nisu samo sadržani u funkcionalnim dijelovima poduzeća već ih je moguće prikupiti i od trećih strana izvan poduzeća.

Za pravilnu implementaciju baze podataka potreban je odgovarajući sustav. Taj sustav je sustav za upravljanje bazom podataka odnosno skraćeno DBMS. DBMS sustav je softversko rješenje koje omogućuje kreiranje, korištenje i kontrolu baze podataka te pristup samoj bazi. Kao što i ističe, Kaštelan (2009.) taj sustav je poslužitelj koji se nalazi između korisnika baze i same baze, odnosno u ime korisnika obavlja sve operacije s podacima.

DBMS sustav ima brojne funkcije. Te funkcije su memoriranje i ažuriranje podataka, održavanje sistemskog kataloga, podrška transakcijama, servis kontrole, podrška komunikaciji i slično. U svojoj knjizi, Kaštelan (2009.) sumira brojne funkcije u pet ključnih područja, a to su:

1. **Definicija podataka** – sustav pretvara podatke u oblik za internu pohranu
2. **Manipulacija podataka** – sustav je manipuliran od strane korisnika, što znači da on mora obrađivati podatke kako to zahtijevaju korisnici
3. **Integritet i zaštita** – podaci se moraju čuvati i sustav mora prepoznati one koji narušavaju integritet
4. **Oporavak** – u slučaju da se podaci izgube, sustav mora imati mogućnost njihovog povrata
5. **Efikasnost** – sve funkcije moraju pružati najbolje performanse

Razvoj baze podataka je složeni zadatak. Takav projekt zahtijeva primjenu raznih metoda i zajednički rad nekoliko stručnjaka. Manger (2014.) smatra kako je to projekt koji se sastoji od pet aktivnosti :

1. **Utvrđivanje i analiza zahtjeva** – u ovom dijelu proučavaju se tokovi informacija, dokumenti, radni procesi, transakcije, postojeći softver te najvažnije od svega promatraju se podaci koje treba pohranjivati. Sve to se radi s ciljem smanjenja redundancije i usklađivanja tehnologije.
2. **Oblikovanje** – odnosi se na međusobno grupiranje, strukturiranje i povezivanje podataka. Glavni rezultat oblikovanja je konačna shema cijele baze. Na to se nadovezuju Maleković i Rabuzin (2016.) koji govore kako postoje logičko i konceptualno oblikovanje baze podataka. Logičko oblikovanje se temelji na zavisnosti između atributa relacijske sheme dok se konceptualno oblikovanje temelji na vezi između koncepata.

3. **Implementacija** – svodi se na fizičku realizaciju oblikovane baze na odgovarajućem računalu. Ovdje veliku ulogu igra DBMS sustav koji olakšava transfer podataka iz različitih izvora u bazu. Nakon unosa podataka, razvijaju se aplikacije za obavljanje transakcija.
4. **Testiranje** – u ovoj fazi korisnici testiraju rade baze i provjeravaju da li ona odgovara zahtjevima. Također glavni cilj ove faze je otkrivanje skrivenih kvarova koji su se možda dogodili u prethodnim fazama.
5. **Održavanje** – kontinuirani proces gdje se kompletna baza i njezini dokumenti podvrgavaju stalnim promjenama.

Na Mangerov razvoj nadovezuju se Buttler i Maklan (2015.) koji definiraju šest ključnih koraka u implementaciji baze podataka, a ti koraci su:

1. **Definiranje funkcija baze podataka** – važno je dati odgovor na pitanje zašto nam je potrebna takva vrsta baze podataka? To znači da se poduzeće treba ponovo sjetiti svoje CRM vizije, strategije, ciljeva, poslovnih slučajeva kako bi se utvrdilo što se očekuje od CRM-a. Generalno, sve osobe koje prakticiraju CRM koriste baze podataka za sva tri njegova oblika, a to su : operativni, analitički i strateški. Strateški CRM upotrebljava podatke povezane s kupcima kako bi utvrdio koje kupce je najbolje targetirati. Operativni CRM koristi podatke vezane uz kupce u svakodnevnom poslovanju prodaje, marketinga i usluga, dok analitički CRM koristi te podatke kako bi pružio potporu donošenju odluka koje imaju za cilj povećanje vrijednosti stvorene za i od kupca.
2. **Definiranje zahtjeva za informacijama** – u ovom dijelu važno je odgovoriti na pitanje koje su najpotrebnije informacije za razvoj baze? Ljudi koji najbolje daju odgovor na to pitanje su oni koji komuniciraju s kupcima u prodaji, marketingu, pružanju usluga te oni koji donose strateške odluke u CRM-u. Definiranje informacija se može vezati uz različita područja kao što je planiranje kampanja, pregledavanje odluka od strane menadžera te različitih CRM aplikacija koje dizajniraju baze podataka u korist kupaca.
3. **Identificiranje izvora podataka** – informacije se mogu dobiti interno i eksterno. Interni podaci temelj su većine CRM programa, iako je količina dostupnih informacija o kupcima ovisi o stupnju kontakta s klijentima koji poduzeće posjeduje.
4. **Odabir tehnologije i operacijskog sustava** – odabir tehnologije i operacijskog sustava najčešće se spominje kod odabira CRM aplikacijskog softvera. Dobavljači CRM aplikacija obično podržavaju točno određenu listu tehnologija baza podataka.

5. **Popunjavanje baze podataka** – nakon što se odlučilo koji podaci su potrebni, koji su zahtjevi baze podataka, sljedeći zadatak je dobiti podatke i unijeti ih u bazu. CRM aplikacije trebaju podatke koji su primjerno točni. Glavni koraci prilikom popunjavanja baze podataka odgovarajućim podacima su: potvrda, provjera, dupliciranje te spajanje i čišćenje podataka.
6. **Održavanje baze podataka** – važno je konstatno ažurirati bazu podataka kako bi bila korisna tijekom cijelog vremena njezinog korištenja.

6.3.1. Sigurnost baze podataka

Sigurnost podataka je pojava od iznimne važnosti za svako poduzeće. U posljednjih nekoliko godina tom pojmu se pridodaje puno pažnje jer ako podaci dođu u tuđe ruke to može nanijeti veliku štetu poduzeću iz kojeg se podaci izvlače. Baze koje se kreiraju godinama, mogu nestati samo u nekoliko minuta. Na temelju toga, Rabuzin (2014.) smatra kako optimalnog rješenja nema, već je važno da se učini niz malih koraka od kojih svaki doprinosi ukupnom povećanju sigurnosti. Osim toga ističe kako su u bazi podataka najvažniji korisnici, objekti te ovlasti kojima se određuje što korisnik smije raditi u bazi.


Baza podataka je dragocijen resurs poduzeća. U njezin nastanak i održavanje uložena je velika količina ljudskog rada. Manger (2014.) zbog toga govori kako bi DBMS sustav trebao osigurati garanciju sigurnosti, što znači da se ne smije dogoditi da podaci budu uništeni zbog kvarova, krivih transakcija, nepažnje korisnika i slično. Osim same sigurnosti važno je čuvati integritet i to prvenstveno korektnost i konzistenost.

Uz sigurnost baze podataka često se spominju različite faze kreiranja zaštite. Dvije najvažnije faze koje se često spominju su kreiranje korisnika te njegova autentikacija. Prilikom korištenja baze podataka svaki korisnik se mora predstaviti. Kada se govori o autentikaciji, Maleković i Rabuzin (2016.) govore kako je ona moguća u nekoliko oblika, točnije moguće je koristiti korisničko ime i lozinku, token ili neke korisnikove karakteristike. Ostale faze u kreiranju zaštite su autorizacija, praćenje promjena, kriptiranje i hashiranje podataka i izrada sigurnosne kopije.

7. Anketa

Uz teorijski dio rada provedeno je i istraživanje u hrvatskim poduzećima. Cilj koji se nastojao postići ovim istraživanjem je stjecanje dojma o tome koliko su domaća poduzeća upoznata s pojmom „Big Data“ te u kojem stupnju se on primjenjuje u poslovanju. Osim velikih podataka, uz pomoć istraživanja pokušalo se saznati da li poduzeća posjeduju CRM sustav te u kojoj mjeri je on kompatibilan s velikim podacima koji se prikupljaju prilikom poslovanja.

Istraživanje je provedeno u obliku ankete koja se sastoji od 20 pitanja. Od dvadeset pitanja, šest pitanja je otvorenog tipa na koja se odgovor daje samostalno vlastitim riječim, dok su ostala pitanja zatvorenog tipa u kojima poduzeća odabiru jedan ili više ponuđenih odgovora.




Grafikon 1. Broj zaposlenih

U anketi je sudjelovalo deset poduzeća, od toga dva poduzeća ima manje od 10 zaposlenika što ih svrstava u skupinu mikro poduzeća, dva poduzeća spadaju u skupinu malih poduzeća sa brojem zaposlenika između 10 i 50, jedno poduzeće je srednje veličine dok najveći broj anketiranih poduzeća spada u skupinu velikih poduzeća sa više od 250 zaposlenika.




Grafikon 2. Stupanj iskustva

Odgovori na pitanje u kojoj mjeri vaše poduzeće ima iskustva s velikim podacima i inovacijama utemeljenima na tim podacima su bili vrlo pozitivni što je jasno vidljivo i na grafikonu. Većina poduzeća je u fazama efektivnog korištenja i fazi provođenja različitih strategija velikih podataka, što daje pozitivan znak o tome kako poduzeća prate novije trendovi u svijetu poslovanja.



Grafikon 3. Pristup podacima

Treće pitanje odnosilo se na ocjenu pristupa. Drugim riječima, rukovodeći su morali procijeniti kvalitetu pristupa relevantnim, točnim i pravodobnim podacima unutar njihove organizacije i temeljem toga dati prikladan odgovor. Na grafikonu je vidljivo kako poduzeća imaju vrlo dobar pristup informacijama unutar poduzeća, što je vrlo važno za pravovremeno donošenje jasnih i detaljnijih odluka.




Grafikon 4. Posjedovanje strategije u %

Četvrtim pitanjem nastojalo se saznati koliko poduzeća ima definirane strategije vezane uz velike podatke i analitiku tih podataka. Iz grafikona je jasno vidljivo kako 80% anketiranih poduzeća ima jasno definiranu strategiju koja im je glavna smjernica prilikom poslovanja.



Grafikon 5. Ocjena rukovoditelja

Na grafikonu su vidljivi odgovori na peto pitanje koje se odnosilo na procjenu sposobnosti rukovoditelja da koriste prikupljenje podatke za poboljšanje poslovanja. Jasno je vidljivo kako rukovoditelji anketiranih poduzeća vrlo adekvatno prikupljaju, analiziraju i zatim koriste te podatke u preobraženju poslovanja.




Grafikon 6. Korištenje podataka po funkcijama

Šestim pitanjem nastojalo se spoznati koje funkcije u poduzeću najviše koriste velike podatke i primjenjuju analitiku tih podataka. Ovo pitanje je bilo višestrukog izbora, pa su anketirana poduzeća mogla označiti više različitih funkcija. Ukupnim zbrojem odgovora došlo se do zaključka kako 60% anketiranih poduzeća najviše koriste velike podatke i analitiku u funkcijama ljudski resursi i razvoj proizvoda. Zatim 50% poduzeća koristi velike podatke u funkciji informacijska tehnologija, analiza kupaca i tržišta te izravni i digitalni marketing. Tri poduzeća primjenjuju analitiku u službi za korisnike i upravljanju prijevarama dok najmanje odgovora je za funkciju upravljanje rizicima, koja je prisutna u samo dva poduzeća.

Sedmo i osmo pitanje su pitanja otvorenog tipa na koja su anketirana poduzeća trebala odgovoriti vlastitim riječima. Tim pitanjima nastojalo se saznati što poduzeća misle koje su najveće poslovne prilike i izazovi u korištenju velikih podataka u poslovanju.


Zaključno tome najveće prilike su izrada podatkovnih proizvoda za klijente, organizacija poslovanja, učinkovita analiza trendova, tržišta i konkurencije, bolje umrežavanje poduzeća, razvijanje analitike za upravljanje rizicima, općenito poboljšanje poslovanja, unaprijeđenje usluge klijentima, bolji odabir djelatnika, veća točnost, bolje donošenje odluka, unaprijeđenje nabavnog lanca, bolja informiranost rukovoditelja i sl.

Najveći poslovni izazovi su nedozrela tehnologija, brzina procesiranja, sigurnost, točnost podataka, ograničenost u pristupu, kvaliteta podataka, vremenska dugotrajnost analize ekstremnih skupova podataka, zaštita tajnosti i sl.



Grafikon 7. Uloga velikih podataka


Deveto pitanje je također višestrukog izbora kojim se nastojalo saznati kakva je uloga inicijativa velikih podataka u anketiranim poduzećima. Na grafikonu je jasno vidljivo kako poduzeća najviše nastoje koristiti velike podatke kao dio operativnog sustava koji će kao takvi pružati potporu svim aktivnostima unutar tog sustava te kao koncept za procjenu. Uz te vodeće uloge u nekim poduzećima nastoje se istovremeno primjenjivati i preostale dvije uloge.



Grafikon 8. Izvori podataka


Deseto pitanje također je bilo višestrukog izbora, te se njime nastojalo saznati koji su to izvori iz kojih anketirana poduzeća prikupljaju velike količine podataka. Ukupnim zbrojem odgovora zaključuje se kako poduzeća najviše prikupljaju podatke preko različitih transakcija kupaca,

društvenih mreža, javno dostupnih podataka te prijava na web stranicama. Uz to neka poduzeća su aktivna i u ostalim načinima prikupljanja kao što su putem telefona, e-poštom, društvenih događanja i sl.



Grafikon 9. Udio vanjskih podataka


Na ovom grafikonu je vidljivo kako 60% poduzeća u svom poslovanju primjenjuje više vanjske podatke u odnosu na unutarnje, od čega četiri poduzeća imaju postotak vanjskih podataka između 41-60%, a kod dva poduzeća skoro u potpunosti prevladavaju vanjski podaci sa više od 90%. Ostalih 40% poduzeća oslanja se više na unutarnje podatke, nego na one prikupljene različitim vanjskim izvorima.



Grafikon 10. Udio podataka za unaprijeđenje


Ovaj grafikon prikazuje kako 70% poduzeća od ukupno prikupljenih podataka koristi veliki dio za poboljšanje poslovanja svoje organizacije. Ovaj podataka je vrlo pozitivan jer pokazuje kako je poduzećima važno konstatno napredovanje kroz kvalitetno prikupljanje i analiziranje podataka. Osim toga veliki udio upotrebe podataka za poboljšanje poslovanja govori kako su poduzeća usmjerena prema kvaliteti, a ne količini podatka. Samo kvalitetno analizirani podaci mogu dovesti do pomaka u poslovanju, što bi značilo da ostali nepotrebni podaci moraju biti odbačeni.

Nakon udjela podataka, postavljeno je pitanje broj 13 kojim se nastojalo saznati koje konkretne koristi poduzeća nastoje postići kroz svoje inicijative velikih podataka. Pitanje je bilo postavljeno u obliku ranga (1-7). Broj jedan označavao je najvažniju korist, a broj sedam najmanje važnu korist. Nakon analiziranja odgovora, zaključak je taj kako top tri koristi koja poduzeća nastoje ostvariti korištenjem velikih podataka su bolji odnosi s kupcima, bolje donošenje odluka i povećanje kvalitete proizvoda i usluga. Koristi koje su bile na posljednja dva mjesta prema važnosti su smanjenje rizika i nove inovacije proizvoda. Koristi koje su se našle na četvrtom i petom mjestu te tako zauzele srednju važnost su povećana prodaja i učinkovite operacije.



Grafikon 11. Mjerila uspjeha


Ovaj grafikon prikazuje vrste mjerila kojima poduzeća planiraju izmjeriti uspjeh alternativa velikih podataka, što je ujedino i pitanje broj 14. Ovdje se radi o pitanju višestrukog izbora jer poduzeća mogu primjenjivati više mjerila istovremeno. Nakon zbrajanja odgovora, zaključak je taj kako najviše poduzeća nastoji svoje rezultate mjeriti kvantitativnim i kvalitativnim mjerilima koja su povezana za uspješnost poslovanja. Dok su mjerila vezana uz IT izvedbu znatno manje zastupljena.



Grafikon 12. Područja usmjerenosti


Grafikon 12., prikazuje domene podataka na koje su najviše usmjerena poduzeća svojom strategijom i inicijativama velikih podataka. Analiziranjem i zbrajanjem odgovora, jasno se vidi kako je najviše poduzeća usmjereno na korisničke podatke te podatke o uslugama i proizvodima. Ovo pitanje je bilo višestrukog izbora, pa se tako uz glavne domene dodatna pažnja posvećuje korisničkim transakcijama i stanju na tržištu. Najmanje pokrivene domene su otkrivanje prijevvara te podaci o nabavnom lancu.

Posljednje pitanje zatvorenog tipa odnosilo se na važnost pojedinih izazova koji se javljaju prilikom poslovanja, a vezani su uz velike podatke. Pitanje se sastojalo od 16 navednih izazova, koja su poduzeća trebala poreda prema razini važnosti, odnosno riječ je o mrežnom pitanju u kojem je potrebno dati jedan odgovor za svaki redak. Nakon analiziranja odgovora izdvojeno je pet izazova koji su se najviše istaknuli, a to su pravovremenost, preveliki volumen, upravljanje nestrukturiranim podacima, kvaliteta podataka i nedostatak tehnologije.



Grafikon 13. Pravovremenost

Ovaj grafikon prikazuje prvi izazov vezan uz velike podatke, a to je pravovremenost. Iz njega je vidljivo kako je za 60% anketiranih poduzeća ovaj izazov vrlo važan, a za 30% poduzeća važan. Zaključaj je taj kako ova poduzeća posvećuju dosta pažnje na pravovremenost svih podataka koje prikupljaju, jer pravovremeno prikupljeni podaci mogu ispoštovati vremenski rok koje je poduzeće zadalo za njihovo analiziranje i upotrebu u daljnjim aktivnostima.




Grafikon 14. Preveliki volumen

Drugi izazov odnosi se količinu podataka koja se prikuplja. Na grafikonu se može vidjeti kako je za 40% poduzeća ovaj izazov od umjerene važnosti. Bez obzira na to, kada se zbroje prve tri razine važnosti vidi se kako i dalje zadovoljavajuć broj poduzeća brine o količini podataka koje prikupljaju.




Grafikon 15. Upravljanje nestrukturiranim podacima

Na ovom grafikonu jasno je vidljivo kako poduzeća ističu važnost pravilnog upravljanja velikim količinama podataka koji se prikupe. Drugim riječima, od ukupnog prikupljenog volumena velikih podataka, veliki broj poduzeća brine o tome dali su podaci strukturirani ili nestrukturirani. Vrlo je važno napraviti tu podjelu iz razloga što nestrukturirani podaci mogu stvarati probleme u poslovanju i time oduzimati dragocijeno vrijeme obavljanja zadanih aktivnosti.



Grafikon 16. Kvaliteta podataka

Četvrti izazov vezan je uz kvalitetu prikupljenih podataka. Na grafikonu 16, jasno je vidljivo kako poduzeća u velikoj mjeri brinu za kvalitetu onoga što prikupljaju. Također važno je naglasiti kako je za poboljšanje poslovanja i odnosa s kupcima važnija kvaliteta, a ne volumen prikupljenih podataka.



Grafikon 17. Nedostatak tehnologije

Peti izazov za poduzeća je nedostatak tehnologije. Svi smo upoznati sa utjecajem zastarjele tehnologije na poslovanje, koja ne može pružiti adekvatnu pomoć u provođenju aktivnosti. Na grafikonu je vidljivo kako je ovaj izazov za većinu poduzeća važan, iz čega je zaključak taj kako ta poduzeća ulažu u novu tehnologiju odnosno nastoje biti u trendu s njom jer im novija tehnologija znatno omogućuje brže i efikasnije poslovanje.

Posljednja četiri pitanja ankete su otvorenog tipa kojima se nastajalo saznati da li poduzeća posjeduju CRM sustav, da li je on kompatibilan sa inicijativama velikih podataka, koje prednost je CRM sustav općenito donio poslovanju te kako je povezanost CRM-a i velikih podataka utjecala na poslovanje. Nakon analiziranja odgovora, mogu zaključiti kako je 50% poduzeća potvrdilo da su inicijative velikih podataka kompatibilne sa njihovim CRM sustavom. Poduzeća koja su istaknula postojanje kompatibilnost također su potvrdila postojanje posebnih konektora za CRM sustav iz kojeg se izvlače podaci te se koriste u daljnjim analizama. Ostalih 50% poduzeća istaknulo je kako trenutno nemaju kompatibilnost, ali postoje planirane strategije povezivanja koje se očekuju ostvariti u bližoj budućnosti. Osim toga potrebna je i obuka zaposlenika za novu vrstu poslovanja.

Zatim, 60% poduzeća koristi CRM sustav u svom svakodnevnom poslovanju. Od poduzeća koja posjeduju CRM sustav, dva poduzeća spajaju se na klijentove servere te koriste njihov sustav, jedno poduzeće je razvilo vlastiti sustav, jedno poduzeće koristi Salesforce cloud CRM sustav dok ostali potvrđuju kako koriste općenito njegovu operativnu i analitičku stranu kojom pružaju podršku ostalim aktivnostima te analiziraju podatke o kupcima.

Tih 60% poduzeća koja posjeduju CRM sustav navela su i prednosti koje je on donio njihovom poslovanju, čime su odgovorili na predzadnje pitanje. Navedene prednosti su bolji pregled prodaje i post-prodaje, jedinstveni pogled na kupce i segmente tržišta, bolje analiziranje i jednostavnije praćenje informacija, sprječavanje prijevara, poboljšanje konkurentnosti, usmjerenost na potrebe kupaca, razvoj novih proizvoda, poboljšanje svakodnevnih operacija te lakše integriranje informacija s drugim poslovnim aktivnostima.

Onih 50% poduzeća koja su potvrdila kompatibilnost velikih podataka i CRM sustava izdvojila su nekoliko poboljšanja, koja su ostvarena upravo povezanošću ta dva sustava i time odgovorili na posljednje pitanje u anketi. Anketirana poduzeća istaknula su kako im je ta povezanost pomogla ostvariti bolju organizaciju, obogaćivanje informacijama, fokusiraniji razvoj proizvoda i usluga, praćenje transakcija, bolje odnose s kupcima, točnije analiziranje i kvalitetnije odluke, benchmarking, kontinuirano poboljšanje procesa te bolje odlučivanje rukovodećih.

8. Zaključak

Dobri odnosi s kupcima trebaju biti stvarnost svakog poduzeća, a ne jedna od želja na popisu koja se želi ostvariti. Važno je konstatno razvijati i održavati te odnose jer na temelju tih odnosa razvija se zadovoljstvo. Zadovoljstvo kupaca je ključan čimbenik u postizanju bilo kakvog napretka u poslovanju. Zadovoljni kupci su glavni pokretači svega, glavne žile kucavice svakog poduzeća i upravo zbog toga mora im se posvetiti velika pažnja, jer bez njih poduzeće je osuđeno na propast. Ljudi svakodnevno prikupljaju velike količine podataka bez da su uopće toga i svjesni. Podatke je moguće prikupljati iz velikog broja različitih izvora za različite svrhe. Jedna od svrha je i poboljšavanje odnosa s kupcima koja se provlači kroz ovaj rad. Drugim riječima, glavni je zadatak ovog rada bio definirati dva relativno nova pojma koja nisu toliko detaljno istražena i dokazati pretpostavku da li su ta dva sustava u mogućnosti djelovati kompatibilno sa zajedničkim ciljem poboljšanja kako odnosa s kupcima tako i kompletnog poslovanja.

Na temelju toga, pojam Big Data, prikazan je i definiran kao način prikupljanja velikih količina podataka koji se kroz vrijeme detaljno analiziraju i koriste za poboljšanje određenog sustava u poduzeću. Uvijek ga je potrebno promatrati kroz tri čimbenika, a to su volumen, raznovrsnost i brzina. Kao zaseban sustav pokazao se vrlo učinkovit u svim područjima marketinga, ali i kao dio strategije upravljanja zadovoljstvom kupaca. Zaključno tome, važno je poznavati analiziranje strukturiranih i nestrukturiranih podataka, ali i razdvajati bitno od nebitnog jer nije uvijek rješenje u volumenu podatka, nego u velikim broju slučajeva važnu ulogu igra i sama kvaliteta podataka.

S druge strane pojam CRM-a, definiran je kao zaseban sustav djelovanja koji služi kao potpora poduzeću u usmjeravanju proizvoda, aktivnosti, usluga i procesa prema željama i potrebama kupaca. Djelovanje u kojem poduzeće kupca stavlja u centar pozornosti donosi nekoliko prednosti kao što su povećanje vrijednosti, napredak u poslovanju, bolji odnosi s kupcima i sl. Zaključno tome, CRM sustav sastoji se od tri dijela, a to su strateški, operativni i analitički. Iako je njegova implementacija malo zahtjevnija i potrebno je detaljno paziti na svaki korak, to i dalje ne stvara sumnju u njegovo pozitivno djelovanje na poslovanje i ostvarivanje prisnijih odnosa s kupcima.

Nakon teorijskog dijela rada, provedeno je primarno istraživanje u obliku ankete. Anketom se nastojala dokazati pretpostavka kompatibilnost CRM sustava i velikih podataka u hrvatskim poduzećima, ali i dokazati stupanj njihova korištenja prilikom poslovanja. U anketi je sudjelovalo pet velikih poduzeća, jedno srednje poduzeće, dva mala poduzeća i dva mikro poduzeća. Rezultati provedene ankete su dosta zadovoljavajući jer većina poduzeća je

upoznata sa velikim podacima i u fazi je njihovog efektivnog korištenja i provođenja. Čak 80% poduzeća ima definiranu strategiju za velike podatke i analitiku tih podataka te još uz to smatraju kako imaju više nego adekvatan pristup podacima u poduzeću. Osim pristupa podacima unutar poduzeća, pozitivno su i ocjenjene namjere rukovodećim u korištenju tih podataka za unaprijeđenje poslovanja.

Od ukupno anketiranih poduzeća, 60% njih primjenjuje velike podatke u funkciji ljudskih resursa te prilikom razvoja proizvoda, dok odmah iz njih se nalaze funkcije informacijska tehnologija, analiza kupaca i tržišta te izravni i digitalni marketing. Uz to, velika većina nastoji koristiti velike podatke kao dio operativnog sustava koji će pružati potporu ostalim aktivnostima unutar poduzeća. Anketirana poduzeća svoje velike podatke najviše prikupljaju iz transakcija, prijava na web stranice, društvenih medija i slično. Prilikom prikupljanja tih podataka, 60% poduzeća oslanja se na vanjske podatke, dok njih 70% koristi veliki dio prikupljenih podataka za unaprijeđenje poslovanja što je vrlo pozitivno jer time se vidi želja konstatnog napretka vlastitog poslovanja. Kroz strategiju velikih podataka, poduzeća su najviše prvo usmjerena na korisničke podatke, podatke o uslugama i proizvodima, a tek zatim na korisničke transakcije i stanje na tržištu.

Također pohvalno je napomenuti kako se anketirana poduzeća u velikoj mjeri brinu za sve poslovne izazove koji se mogu pojaviti vezano uz velike podatke i konstantno nastoje smanjiti njihovo jačanje i utjecaj na poslovanje. Neki od izazova na koje su najviše fokusirani su pravovremenost, volumen, pravilno upravljanje nestrukturiranim podacima, kvaliteta podataka, nedostatak tehnologije i slično. Zatim, 60% anketiranih poduzeća primjenjuje CRM sustav u svakodnevnom poslovanju, a njih 50% je izjavilo kako postoji veza između inicijativa velikih podataka i CRM sustava, odnosno ta dva sustava primjenjuju kompatibilno u svom poslovanju. Dok ostalih 50% poduzeća nastoji povezati ta dva sustava u bližoj budućnosti.

Konačni zaključak je taj da je uz pomoć primarnog i sekundarnog istraživanja potvrđena pretpostavka o postojanju pozitivne kompatibilnosti između velikih podataka i CRM sustava. Ta dva sustava mogu zajedno djelovati i donijeti mnoge prednosti poduzećima kao što su bolja organizacija, bolji razvoj proizvoda i usluga, bolje praćenje kupaca i njihovih transakcija, bolje targetiranje kupaca, poboljšanje procesa, kvalitetnije odluke, točnije analiziranje, kvalitetniji odnosi s kupcima i slično. Također više poduzeća u budućnosti bi trebalo shvatiti važnost kvalitetnih odnosa s kupcima kao i kompatibilnost ova dva sustava te ih početi više primjenjivati u provođenju svojih strategija i ciljeva. Jer na kraju uvijek je najbolja win-win situacija u kojoj profitiraju kupci, ali i kompletno poduzeće.

Popis literature

Knjige i članci:

1. Allen, R.D., (2004) *Customer satisfaction research management, a comprehensive guide to integrating customer loyalty and satisfaction metrics in the management of complex organizations*, ASQ Quality Press
2. Anderson, K.L., Kerr, C.J., (2002.) *Customer Relationship Management*, The McGraw-Hill Companies, Inc.
3. Armstrong, G., Kotler, P., Harker, M. and Brennan, R. (2009), *Marketing – An Introduction*, 1st ed (ed.), Prentice Hall, London
4. Arthur, L. (2013.), *Big Data Marketing: Engage Your Customers More Effectively and Drive Value*, John Wiley & Sons, Inc
5. Banasiewicz A.D. (2013.), *Marketing Database Analytics: Transforming Data for Competitive Advantage*, Taylor & Francis
6. Barbir, S., [et.al]; urednik Dobrinić, D. (2011.), *Marketing i baze podataka*, Fakultet organizacije i informatike Varaždin, CRODMA - Hrvatska udruga za direktni i interaktivni marketing
7. Berman, J.J. (2013), *Principles of Big Data: Preparing, Sharing, and Analyzing Complex Information*, Elsevier Inc
8. Blattberg, R.C., Byung-Do K., Neslin, S. A. (2008.), *Database Marketing: Analyzing and Managing Customers*, Springer Science+Business Media, LLC
9. Brodarić, A. (2010.), *Faze implementacije i funkcionalosti CRM-a*, 18. Telekomunikacijski forum TELFOR 2010, Beograd, str. 102-105
10. Buttle, F., Maklan, S., (2015.) *Customer Relationship Management: Concepts and Technologies*, 3rd edition, Routledge
11. Berry, M., Linoff, G.S., (2004.) *Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management*, Wiley Publishing, Inc., Indianapolis, Indiana
12. Caufield, S., (2001.) *Customer Relationship Management - The Ultimate Guide to the Efficient Use of CRM*, Friedr. Vieweg & Sohn Verlagsgesellschaft mbH
13. Car, D., (2013.) *Upravljanje odnosima s kupcima : priručnik za polaznike*, Zagreb : Algebra učilište
14. Cunningham, M.J., (2002.) *Customer Relationship Management*, Capstone Publishing, United Kingdom

15. Dobrinić, D., Gregurec, I., (2016.) *Integrirani marketing*, Mediaprint Tiskara Hrastić, Zagreb
16. Dyché, J., (2001.) *CRM Handbook, A Business Guide to Customer Relationship Management*, Addison Wesley
17. Grigoroudis, E., Siskos, Y., (2010.) *Customer Satisfaction Evaluation- Methods for Measuring and Implementing Service Quality*, Springer Science+Business Media, LLC
18. Gutić, D., Bačelić, J., Bačelić, Z., (2011.) *Istraživanje tržišta (po marketing konceptu)*, Osijek, Grafika
19. Hassan, S.R., Nawaz, A., Lashari, N.M., Zafar, F., (2015.) *Effect of Customer Relationship Management on Customer Satisfaction*, Procedia Economics and Finance 23, 563 – 567
20. Hurwitz, J., Nugent, A., Halper, F., Kaufman, M., (2013.) *Big Data For Dummies*, John Wiley & Sons, Inc.
21. Kaštelan, T., (2009.) *Uvod u baze podataka - priručnik*, Algebra, Zagreb
22. Kesić, T., (1999.) *Ponašanje potrošača*, Zagreb, Adeco
23. Khana, A., Ehsanb, N., Mirzac, E., Sarwar, S.Z., (2012.) *Integration between Customer Relationship Management (CRM) and Data Warehousing*, Procedia Technology 1 239-249
24. Knapp, M., (2013), *Big Data*, Journal of Electronic Resources in Medical Libraries, Vol. 10, No. 4, pp. 215-222
25. Kocijan, K., (2014.) *Big Data: kako smo došli do velikih podataka i kamo nas oni vode*, Zavod za informacijske studije, Zagreb, str. 37-62
26. Kotler, P., Armstrong, G., (2017.) *Principles of Marketing (17th edition)*, Pearson Education Limited
27. Kotler, P., Keller, K.L., (2008.) *Upravljanje marketingom 12. izdanje*, Zagreb, MATE
28. Kotler, P., Wong, V., Saunders, J., Armstrong, G., (2006.) *Osnove marketinga 4. europsko izdanje*, Zagreb, MATE
29. Kumar, V., Reinartz, W., (2012.) *Customer Relationship Management-Concept, Strategy, and Tools*, Springer-Verlag Berlin Heidelberg
30. Long, S.C., Khalafinezhad, R., Ismail, W., Rasid, C., (2013.) *Impact of CRM Factors on Customer Satisfaction and Loyalty*, Asian Social Science; Vol. 9, No. 10, str. 247-253
31. Maleković, M., Rabuzin, K., (2016.) *Uvod u baze podataka*, Fakultet organizacije i informatike Varaždin, Mini-Print- Logo, Varaždin
32. Manger, R., (2014.) *Baze podataka*, Sveučilište u Zagrebu, Element
33. Marr, B., (2015) *BIG DATA - Using Smart Big Data Analytics and Metrics To Make Better Decisions and Improve Performance*, John Wiley & Sons Ltd

34. Mayer-Schonberger, V., Cukier, K., (2013.) *Big Data - A Revolution That Will Transform How We Live, Work, and Think*, Houghton Mifflin Harcourt
35. Muller, J., Srića, V., (2005.) *Upravljanje odnosima s klijentima – primjenom CRM poslovne strategije do povećanja konkurentnosti*, Zagreb, Delfin
36. Moorthy, J., Lahiri, R., Biswas, N., Sanyal, D., Ranjan, J., Nanath, K., Ghosh, P., (2015.) *Big Data: Prospects and Challenges*, VIKALPA The Journal for Decision Makers 40(1) 74–96
37. Oliver, L.R., (2010.) *Satisfaction - A Behavioral Perspective on the Consumer*, Routledge
38. Phelps, R.G., (2008.) *Customer relationship managemet*, Thorogood
39. Raab, G., Ajami, A.R., Gargeya, B.V., Goddard, J.G., (2008.) *Customer Relationship Management A Global Perspective*, Gower Publishing Company
40. Rabuzin, K., (2014.) *SQL napredne teme*, Fakultet organizacije i informatike Varaždin, Zrinski
41. Rubinstein, S.I., (2013.) *Big Data: The End of Privacy or a New Beginning?*, International Data Privacy Law, 2013, Vol. 3, No. 2, str. 74-87
42. Schmid, J., Weber, A., (1998.) *Desktop Database Marketing*, NTC Contemporary
43. Strong, C., (2015.) *Humanizing Big Data - Marketing at the Meeting of Data, Social Science and Consumer Insight*, Kogan Page
44. Šebalj, D., Živković, A., (2016.) *Promjene u upravljanju podacima koje nosi „Big data“*, Sveučilište J. J. Strossmayera u Osijeku, Ekonomski fakultet u Osijeku, No. 16-01, str. 1-23
45. Tapp, A., Whitten, I., Housden, M., (2014) *Principles of Direct Database & Digital Marketing fifth edition*, Pearson Education Limited
46. Todman, C., (2000.) *Designing a Data Warehouse: Supporting Customer Relationship*, Prentice Hall PTR
47. Tsiptsis, K., Chorianopoulos, A., (2009.) *Data Mining Techniques in CRM - Inside Customer Segmentation*, John Wiley & Sons, Ltd
48. Vranešević, T., (2000.) *Upravljanje zadovoljstvom klijenata*, Zagreb, Golden marketing
49. Wahl, A., (2005.) *Customer Data Warehouse (seminar)*, University of Fribourg, Switzerland Department of Informatics, preuzeto s [http://diuf.unifr.ch/is/studentprojects/pdf/reports/CRM_SS05_Customer_Data_Warehouse_\(AlainWahl\).pdf](http://diuf.unifr.ch/is/studentprojects/pdf/reports/CRM_SS05_Customer_Data_Warehouse_(AlainWahl).pdf)
50. Yadav, R., Monika, Kumar, T., Garima, (2015) *Usage of Big Data Analytics for Customer Relationship Management*, International Journal of Advanced Research in Computer Science, Volume 6, No. 2, str. 1-3

51. Yates, B.R.,(2013.) *Big Data or Right Data?*, In Proceedings of International Workshop on Foundations of Data Management, CEUR Proceedings, vol. 1087, str. 1-7

Ostali izvori:

1. Agiratech (bez. dat.) *Integrating Big Data into company's CRM*, preuzeto 14.5.2018. s <http://www.agiratech.com/big-data-crm/>
2. Agarwal, A., (2012.) *Importance of CRM for customer satisfaction*, preuzeto 30.4.2018. s <https://www.projectguru.in/publications/importance-of-crm-for-customer-satisfaction/>
3. Barrett, J., (2016.) *Customer satisfaction : How to Drive, Kill, Measure & Sustain It*, preuzeto 18.4.2018. s <https://www.getfeedback.com/blog/customer-satisfaction/>
4. Bowden, J., (2014.) *The New 4Ps of Marketing With Big Data*, preuzeto 23.6.2018. s <https://www.socialmediatoday.com/content/new-4ps-marketing-big-data>
5. Columbus, L., (2016.) *Ten Ways Big Data Is Revolutionizing Marketing And Sales*, preuzeto 3.4.2018. s <https://www.forbes.com/sites/louiscolumbus/2016/05/09/ten-ways-big-data-is-revolutionizing-marketing-and-sales/#33741a9321cf>
6. Danyel, C., (2017.) *The three different types of CRM and what they offer*, preuzeto 10.5.2018. s <https://discovercrm.com/different-types-of-crm.html>
7. Dennis, L.A., (2016.) *Big Data and Smart Data: Big Drivers for Smart Decision Making*, preuzeto 1.4.2018. s <http://www.dataversity.net/big-data-smart-data-big-drivers-smart-decision-making/>
8. Franklin, T., (2014.) *CRM and Big Data*, preuzeto 14.5.2018. s <https://www.crmswitch.com/crm-industry/crm-and-big-data/>
9. IBM, (bez dat.) *Big Data Analytics*, preuzeto 29.3.2018. s <https://www.ibm.com/analytics/hadoop/big-data-analytics>
10. Joenn, A., (2011.) *What is Analytical CRM?*, preuzeto 11.5.2018. s <https://www.collierpickard.co.uk/crmblog/analytical-crm/>
11. Kierczak, L., (bez dat.) *5 Reasons Why Customer Satisfaction Is Important*, preuzeto 12.4.2018. s <https://survicate.com/customer-satisfaction/importance-customer-satisfaction/>
12. Marr, B., (2015.) *The SMART alternative to Big Data*, preuzeto 1.4.2018. s <https://www.fm-magazine.com/issues/2015/may/big-data-alternatives-bernard-marr.html>
13. Marr, B., (bez dat.) *What is Big Data? A Super Simple Explanation For Everyone*, preuzeto 1.4.2018. s <https://www.bernardmarr.com/default.asp?contentID=766>
14. Marr, B., (bez dat.) *How Is Big Data Used In Practice? 10 Use Cases Everyone Must Read*, preuzeto 1.4.2018. s <https://www.bernardmarr.com/default.asp?contentID=1076>

15. Martin, (2014.) *Best Uses of Big Data in Marketing*, preuzeto 3.4.2018. s <https://www.cleverism.com/best-uses-big-data-marketing/>
16. Matteson, L., (2013.) *The Three Types of CRM Systems*, preuzeto 10.5.2018. s <https://www.drivingsales.com/lawry-matteson/blog/20130327-the-three-types-crm-systems->
17. Meyers, S., (2017.) *CRM & Big Data Analytics*, preuzeto 14.5.2018. s <https://www.rolustech.com/blog/crm-big-data-analytics/>
18. Miglani, S., (2016.) *Big Data and Small Data: What's the Difference?*, preuzeto 1.4.2018. s <http://www.dataversity.net/big-data-small-data/>
19. Oracle, (bez dat.) *PeopleSoft Enterprise CRM Warehouse*, preuzeto 22.5.2018. s <http://www.oracle.com/us/products/applications/peoplesoft-enterprise/financial-management/064735.html>
20. Paine, J., (bez dat.) *Big Data in Marketing: 5 Use Cases*, preuzeto 12.4.2018. s <https://www.inc.com/james-paine/5-ways-big-data-is-changing-marketing.html>
21. Rouse, M., (2015.) *Big Data CRM*, preuzeto 14.5.2018. s <https://searchcrm.techtarget.com/definition/big-data-CRM-big-data-customer-relationship-management>
22. Sas, (bez dat.) *Big Data – What it is and why it matters*, preuzeto 29.3.2018. s https://www.sas.com/en_us/insights/big-data/what-is-big-data.html
23. Shukla, D., (bez dat.) *How Big Data is Changing Digital Marketing*, preuzeto 5.4.2018. s <https://channels.theinnovationenterprise.com/articles/how-big-data-plays-an-important-role-in-the-success-of-digital-marketing>
24. Shah, M., (2016.) *Advantages and Disadvantages of Open Source CRM System*, preuzeto 13.5.2018. s <https://www.biztechcs.com/blog/advantages-disadvantages-crm-system/>
25. Smith, T., (2014.) *How to Measure Customer Satisfaction*, preuzeto 29.4.2018. s <http://www.insightsfromanalytics.com/blog/bid/391487/How-to-Measure-Customer-Satisfaction>
26. Spencer, J., (2014.) *5 Ways Marketers Can Actually Use Big Data*, preuzeto 5.4.2018. s <https://www.salesforce.com/blog/2014/11/5-ways-marketers-can-actually-use-big-data-gp.html>
27. Straightmarketing, (bez dat.) *Analytical Customer Relationship Management*, preuzeto 11.5.2018. s http://www.straightmarketing.com/analytical_customer_relationship_management.asp
28. Straightmarketing, (bez dat.) *Operational Customer Relationship Management*, preuzeto 10.5.2018. s http://www.straightmarketing.com/operational_customer_relationship_management.asp

28. Taylor, M., (2014.) *Advantages of Customer Relationship Management*, preuzeto 13.5.2018. s <http://crm.walkme.com/advantages-customer-relationship-management/>
29. Thakral, R., (2017.) *Advantages and Disadvantages of CRM*, preuzeto 13.5.2018. s <https://www.targetintegration.com/advantages-and-disadvantages-of-crm/>
30. Zasso, J., (2016.) *What is an “Operational“ CRM? CRM Types and What They Mean*, preuzeto 10.5.2018. s https://www.lessannoyingcrm.com/resources/operational_CRM

Popis slika

Slika 1. Koncept 3V	4
Slika 2: Tipovi podataka	9
Slika 3. SMART model	12
Slika 4: SMART strategijski predložak	14
Slika 5. Razlika starog i modernog kupca	20
Slika 6. Sadržaj metode tajne kupnje	35
Slika 7. Povezanost CRM-a i CSM-a	39
Slika 8. Razine operativnog CRM-a	45
Slika 9. Analitički CRM	47
Slika 10. Koraci CRM implementacije	51
Slika 11. CRM implementacijska matrica	52
Slika 12. Veliki podaci u CRM-u	57

Popis tablica

Tablica 1. Razlika TPS i DSS sustava obrade	60
---	----

Popis grafikona

Grafikon 1. Broj zaposlenih.....	64
Grafikon 2. Stupanj iskustva	65
Grafikon 3. Pristup podacima	65
Grafikon 4. Posjedovanje strategije u %	66
Grafikon 5. Ocjena rukovoditelja.....	66
Grafikon 6. Korištenje podataka po funkcijama.....	67
Grafikon 7. Uloga velikih podataka	68
Grafikon 8. Izvori podataka.....	68
Grafikon 9. Udio vanjskih podataka	69
Grafikon 10. Udio podataka za unaprijeđenje	69
Grafikon 11. Mjerila uspjeha	70
Grafikon 12. Područja usmjerenosti.....	71
Grafikon 13. Pravovremenost	72
Grafikon 14. Preveliki volumen	72
Grafikon 15. Upravljanje nestrukturiranim podacima	73
Grafikon 16. Kvaliteta podataka.....	73
Grafikon 17. Nedostatak tehnologije.....	74